

Možnosti biometrické identifikace onkologických pacientů na základě metod zpracování obrazu

Methods of Biometrical Identification of Oncological Patients based on Image Processing Methods

Bc. Aneta Litviaková

Diplomová práce

Vedoucí práce: Ing. Jan Kubíček Ph.D.

Ostrava, 2021

Abstrakt

Cílem diplomové práce je objasnit možnosti biometrické identifikace v klinickém použití a vytvořit systém biometrické identifikace pro onkologické pacienty na základě metod zpracování obrazu. Teoretická část se zabývá popisem strukturálních změn v lidském organismu, které jsou způsobeny podstupováním radioterapie a chemoterapie. Důraz je kladen i na rozbor biometrického systému a jeho vlastností. Popsané jsou různé metody biometrické identifikace, jako například identifikace založená na otisku prstu, obličeje či duhovky. Praktická část se zabývá tvorbou systému biometrické identifikace na základě rozpoznávání obličeje v prostředí MATLAB. Akvizice dat proběhla na oddělení Cyberknife ve Fakultní nemocnici v Ostravě. Implementace systému se skládá ze dvou hlavních částí: extrakce příznaků obličeje a její následná klasifikace a rozpoznání. Součástí praktické části je zhodnocení vybraných biometrických metod na základě jejich efektivity a robustnosti, testování různých vlivů ovlivňujících úspěšnost a tvorba uživatelského grafického rozhraní.

Klíčová slova

Biometrická identifikace, Onkologie, Zpracování obrazu,

Abstract

The aim of the diploma thesis is to clarify the possibilities of biometric identification in clinical use and to create a system of biometric identification for cancer patients based on image processing methods. The theoretical part deals with the description of structural changes in the human body, which are caused by undergoing radiotherapy and chemotherapy. Emphasis is also placed on the analysis of the biometric system and its properties. Various methods of biometric identification are described, such as identification based on a fingerprint, face or iris. The practical part deals with the creation of a biometric identification system based on a face recognition in the MATLAB. Data acquisition took place at the Cyberknife department at the University Hospital in Ostrava. The implementation of the system consists of two parts: extraction of facial features and classification and recognition of the face. The practical part also includes the evaluation of selected biometric methods based on their effectiveness and robustness, testing of various influences affecting success and the creation of a graphical user interface.

Key words

Biometric identification, Oncology, Image processing,

PodĎakovanie

Týmto by som chcela poďakovať vedúcemu práce Ing. Janovi Kubíčkovi Ph.D. za trpezlivé vedenie, ústretový prístup a poskytnuté informácie k mojej práci. Taktiež by som rada poďakovala Ph.D. Lukášovi Knybelovi, ktorý pracuje ako zásahový technik prístroja CyberKnife vo Fakultnej Nemocnici v Ostrave. Jeho pomoc pri získavaní dát, jeho cenné rady a poznámky dopomohli k zhotoveniu tejto práce. V neposlednom rade moja vďaka patrí všetkým zúčastneným, či už pacientom onkologického oddelenia FNO alebo môjmu priateľovi, známym a rodine, ktorí boli ochotní podstúpiť fotografovanie na účely testovania vyvinutého biometrického systému.

Obsah

Zoznam použitých termínov	- 6 -
Zoznam použitých skratiek	- 7 -
Zoznam obrázkov	- 8 -
Zoznam tabuliek	- 9 -
Úvod.....	- 10 -
1 Vplyv rádioterapie a chemoterapie na štruktúrne zmeny biologického organizmu	- 11 -
1.1 Rádioterapia	- 11 -
1.2 Chemoterapia	- 12 -
1.3 Nežiadúce zmeny na tele pacienta pri rádioterapii a chemoterapii	- 13 -
1.3.1 Akútne vedľajšie účinky pri rádioterapii.....	- 13 -
1.3.2 Chronické vedľajšie účinky pri rádioterapii.....	- 14 -
1.3.3 Vedľajšie účinky pri chemoterapii.....	- 15 -
2 Princípy biometrickej identifikácie na základe analýzy obrazu	- 17 -
2.1 Biometrická identifikácia	- 17 -
2.2 Základné pojmy	- 17 -
2.3 Princíp biometrického systému	- 18 -
2.4 Základné vlastnosti biometrického systému	- 19 -
2.5 Biometrické charakteristiky.....	- 20 -
2.5.1 Odtlačok prsta	- 20 -
2.5.2 Tvár.....	- 22 -
2.5.3 Dúhovka oka.....	- 24 -
2.5.4 Ostatné biometrické charakteristiky.....	- 25 -
2.6 Chyby pri porovnávaní biometrických dát.....	- 25 -
3 Rešerš metód biometrickej identifikácie s potenciálom využitia v klinických podmienkach.....	- 27 -
3.1 Príprava rešerše	- 27 -
3.2 Prehľadová časť	- 27 -
3.3 Rešerš vybraných článkov.....	- 29 -
3.3.1 Biometrická identifikácia pacientov podstupujúcich rádioterapiu	- 29 -
3.3.2 Rozpoznávanie odtlačkov prstov, ktoré pomáha pri každodennej identifikácii pacientov s rádioterapiou	- 30 -
3.3.3 Implementácia rozpoznávania tváre na overenie pacientov pomocou Microsoft Kinect v2 senzoru.....	- 32 -

3.3.4 Správna starostlivosť pre správneho pacienta v akokoľvek čase.....	- 34 -
3.3.5 Ako môže biometria uzdraviť zdravotníctvo	- 35 -
3.4 Sumarizácia a záver rešerše.....	- 37 -
3.5 Porovnanie metód biometrickej identifikácie a výber najvhodnejšej metódy	- 38 -
4 Akvizícia dát na biometrickú identifikáciu onkologických pacientov	- 39 -
4.1 Autorské práva a etický kódex.....	- 42 -
4.2 Rôznorodosť dát	- 42 -
5 Implementácia a evaluácia metód biometrickej identifikácie na základe spracovania obrazu	- 43 -
5.1 Metódy na extrakciu príznakov	- 44 -
5.1.1 Analýza hlavných komponentov	- 44 -
5.1.2 Lineárna diskriminačná analýza	- 46 -
5.1.3 Konvolučné neurónové siete.....	- 47 -
5.1.4 Porovnanie metód na extrakciu príznakov	- 49 -
5.2 Metódy na určovanie zhody	- 49 -
5.2.1 Porovnanie metrík na určenie vzdialenosti.....	- 50 -
6 Testovanie vybraných metód na biometrickú identifikáciu tváre.....	- 52 -
6.1 Vplyv odlišných vlastností fotiek na úspešnosť rozpoznávania.....	- 52 -
6.2 Vplyv zmeny vzhľadu tváre na úspešnosť rozpoznávania	- 54 -
6.3 Vplyv množstva tréningových fotiek na úspešnosť rozpoznávania	- 55 -
7 Vyhodnotenie a selekcia metódy na základe efektivity a robustnosti	- 56 -
8 Tvorba používateľského rozhrania vybranej biometrickej metódy.....	- 58 -
8.1 Nasnímanie tváre.....	- 58 -
8.2 Aktualizácia databázy a tréningový proces.....	- 60 -
8.3 Predikcia identity a rozpoznávanie snímok	- 62 -
Záver.....	- 64 -
Použitá literatúra	- 65 -
Zoznam príloh.....	- 68 -

Zoznam použitých termínov

Termín	Význam termínu
CCD snímač	charge-coupled device, nábojovo viazaný snímač
Deskvamácia	odlupovanie odumretých častok pokožky
Eigenvectors	vlastné vektory používané v metóde PCA
Eigenvalues	vlastné hodnoty používané v metóde PCA
En face	čelný pohľad
Erytém	začervenanie, je dôsledkom vysokého prekrvenia pokožky
Extravazácia	unikanie lieku do tkaniva v okolí žily
Flebitída	zápalové ochorenie povrchových žíl
Imunosupresia	potlačenie imunologických v organizme
Komorbidity	prítomnosť jedného alebo viac chorôb vyskytujúcich sa súčasne s primárnou chorobou
Mukozitída	zápalové alebo vredové poškodenie slizníc
Osteonekróza	poškodenie kosti ionizujúcim žiarením (hlavne v oblasti ústnej dutiny)
Periférna neuropatia	nedostatočné reakcie v prstoch na rukách a nohách
Reverzibilný	vratný, schopný spätného procesu
Teratogenita	toxické účinky na embryo, spôsobujúce vrodené chyby
Ulcerácia	tvorba vredov
Xerostómia	znížené množstvo slín v ústach

Zoznam použitých skratiek

Skratka	Význam skratky
CNN	Konvolučné neurónové siete
EBGM	Elastický porovnávací diagram
EER	Miera vyrovnaných chýb
EIZ	Elektronické informačné zdroje
FAR	Miera chybného prijatia
FNO	Fakultná Nemocnica v Ostrave
FRR	Miera chybného odmietnutia
FTA	Miera neschopnosti snímať
FTE	Miera neschopnosti registrovať
FTM	Miera neschopnosti porovnať
GDPR	Nariadenie o ochrane osobných údajov
HSV	Farebný model založený zo zložiek: odtieň, sýtosť, jas
IT	Informačné technológie
LDA	Lineárna diskriminačná analýza
LDA	Lineárna diskriminačná analýza
LED	Luminiscenčná dióda
NN	Metóda najbližšieho suseda
PCA	Analýza hlavných komponentov
RGB	Farebný model zložený zo zložiek: červená, zelená, modrá
YCbCr	Farebný model používaný vo videách a digitálnej forme

Zoznam obrázkov

Obrázok 1: Princíp chemoterapie	12 -
Obrázok 2: Obnova vlasov po chemoterapii.....	16 -
Obrázok 3: Rozdiel medzi identifikáciou a verifikáciou	17 -
Obrázok 4: Proces systému biometrickej identifikácie	19 -
Obrázok 5: Druhy markantov otláčkov prsta.....	21 -
Obrázok 6: Proces spracovania odtlačku prsta	22 -
Obrázok 7: Všeobecné antropologické body	23 -
Obrázok 8: Proces spracovania snímky dúhovky.....	24 -
Obrázok 9: Vzťah medzi FAR, FRR a EER	26 -
Obrázok 10: Závislosť skóre odtlačkov s dobrou so zlou kvalitou v závislosti na frakcii.....	31 -
Obrázok 11: Polohy a orientačné body na tvári	32 -
Obrázok 12: Veľkosť trhu s biometrickými systémami v USA s technológiami 2014-2025 ..	35 -
Obrázok 13: Snímky onkologických pacientov FNO z trénovacej databázy	39 -
Obrázok 14: Snímky onkologických pacientov FNO z testovacej databázy.....	39 -
Obrázok 15: Vybrané snímky do testovacej databázy tváří z AT&T.....	40 -
Obrázok 16: Vybrané snímky do testovacej databázy tváří z FACES94.....	40 -
Obrázok 17: Ukážka vytvorenej trénovacej databázy tváří.....	41 -
Obrázok 18: Blokový diagram procesu identifikácie tváre z implementačného hľadiska	43 -
Obrázok 19: Prevod 2D snímku do 1D vektoru	44 -
Obrázok 20: Priemerné obrázky z trénovacej sady (zlava AT&T, faces94, FNO).....	45 -
Obrázok 21: Ukážka eigenfaces z trénovacej sady.....	45 -
Obrázok 22: Ukážka Fisherfaces z trénovacej sady.....	46 -
Obrázok 23: Podvzorkovanie metódou výberu najvyššej hodnoty	48 -
Obrázok 24: Trénovací proces pomocou konvolučnej neurónovej siete.....	48 -
Obrázok 25: Porovnanie dosahu Euklidovskej a Manhattanskej metriky [zdroj: autorka]	50 -
Obrázok 26: Ukážka zmenených klasifikačných vrstiev z predučenej siete GoogLeNet	51 -
Obrázok 27: Vplyv výrazu tváre a zatvorených očí na rozpoznanie tváre	52 -
Obrázok 28: Vplyv orezania na rozpoznanie tváre (snímka z databázy pacientov FNO)	53 -
Obrázok 29: Vplyv rozlíšenia a výrazu na rozpoznanie tváre (snímka z databázy faces94)....	53 -
Obrázok 30: Vplyv pootočenia tváre na rozpoznanie tváre (z databázy Moja databáza)	53 -
Obrázok 31: Vplyv fúzov a účesu na rozpoznanie tváre (snímka z databázy pacientov FNO)-	54 -
Obrázok 32: Vplyv okuliarov na rozpoznanie tváre (z databázy Moja databáza).....	54 -
Obrázok 33: Závislosť počtu fotiek jednej osoby na úspešnosti rozpoznávania.....	55 -
Obrázok 34: Blokový diagram jednotlivých častí biometrického systému	58 -
Obrázok 35: Ukážka okna „Nasnímanie snímok“ v aplikácii MATLAB	59 -
Obrázok 36: Ukážka karty „Aktualizácia databázy“ v aplikácii MATLAB (voľba metódy).....	60 -
Obrázok 37: Karta „Aktualizácia databázy“ po ukončení trénovacieho procesu	61 -
Obrázok 38: Karta „Rozpoznávanie snímok“ pred započatím procesu predikcie identity.....	62 -
Obrázok 39: Ukážka okna „Rozpoznanie snímok“ po spustení predikcie identity.....	63 -

Zoznam tabuliek

<i>Tabuľka 1: Základné vlastnosti vybraných biometrických metód</i>	<i>20 -</i>
<i>Tabuľka 2: Prehľadná charakteristika zdrojov, z ktorých bolo čerpané.</i>	<i>27 -</i>
<i>Tabuľka 3: Prehľadná charakteristika zdrojov, z ktorých bolo čerpané v rešerži.</i>	<i>28 -</i>
<i>Tabuľka 4: Rozličné vlastnosti a vplyvy na snímky v databázach AT&T a FACES94</i>	<i>41 -</i>
<i>Tabuľka 5: Úspešnosť rozpoznania rozličných metrík s využitím metódy najbližšieho suseda-</i>	<i>50 -</i>
<i>Tabuľka 6: Porovnanie úspešnosti jednotlivých metód použitých v tréningovom procese</i>	<i>56 -</i>

Úvod

Identifikácia pacientov s onkologickým ochorením je nepochybne komplikovaná, keďže v dôsledku agresívnej liečby sa vzhľad pacienta výrazne mení. Pri podstupovaní rôznych terapeutických postupov, ktorých cieľom je poskytnúť človeku úľavu, uzdravenie alebo aspoň predĺženie života, sa prejavujú ďalšie vedľajšie účinky spojené s liečbou.

Cieľom tejto diplomovej práce je zjednodušiť identifikáciu onkologických pacientov a tým zvýšiť istotu, že nedôjde k omylu pri podávaní správnej formy a dávky terapie. Akákoľvek chyba, ktorá by nesprávne identifikovala pacienta, sa môže stať pre človeka život ohrozujúcou, v najhorších prípadoch až smrteľnou. Preto je nesmierne dôležité dôkladné posúdenie vplyvov rádioterapie a chemoterapie na telo pacienta, ktorému sa budeme venovať hneď na začiatku tejto diplomovej práce. Keďže sa liečba zvyčajne aplikuje v niekoľkých cykloch, vzhľad pacienta sa bude meniť postupne.

Následne sa oboznámime s princípmi biometrickej identifikácie na základe analýzy obrazu. Medzi najznámejšie metódy, s ktorými sa často stretávame aj pri letiskových kontrolách a iných zabezpečených miestach patrí identifikácia pomocou otlaka prsta, dlane, tváre, hlasu, či pomocou sietnice. Ešte prednedávnom bola biometrická identifikácia považovaná ako okrajová metóda, väčšina osobných informácií bola ukladaná v papierovej podobe. Tento štandard sa však postupne mení, keďže bezpečnosť papierových dát s citlivými informáciami je nedostatočná. Rozvoju biometrickej identifikácie napomáha vývoj polovodičových senzorov detekujúcich obrazové informácie, minimalizácia komplexných súčiastok, či vznik algoritmov pre analýzu a extrakciu obrazu.

Z rôznych druhov biometrickej identifikácie vyberieme tú najvhodnejšiu, ktorá bude v tomto špecifickom využití pokiaľ možno najpresnejšia. Výber najvhodnejšej metódy budeme posudzovať po dôkladnej rešerši z dostupných vedeckých článkov, ktoré sa venujú problematike biometrickej identifikácie v klinickom prostredí. Súčasťou bude aj prehľadné a ucelené zhodnotenie výhod a negatív rôznych metód biometrickej identifikácie z rozdielnych hľadísk.

Pred implementáciou je potrebná akvizícia dát, ktorá prebehne na onkologickom oddelení Fakultnej nemocnice v Ostrave. Na následnú tvorbu systému biometrickej identifikácie na základe spracovania obrazu bude použitý software MATLAB.

Vytvorený systém bude následne otestovaný na viacerých dátach a taktiež sa zameriame na zlepšenie detailov tak, aby bola biometrická identifikácia čo najefektívnejšia a najpresnejšia. Súčasťou diplomovej práce bude aj zhodnotenie robustnosti a efektivity rôznych možností biometrickej identifikácie v špecifickom využití pre onkologických pacientov.

1 Vplyv rádioterapie a chemoterapie na štruktúrne zmeny biologického organizmu

1.1 Rádioterapia

Rádioterapia je metóda, ktorá využíva ionizujúce žiarenie na zastavenie rastu alebo zničenie nádorových buniek. Na ožarovanie postihnutého orgánu sa používa zväzok urýchlených elektrónov či fotónov, ktoré sú veľmi presne nasmerované na objem ožarovaného tkaniva. Ionizujúce žiarenie poškodzuje DNA rakovinovej bunky, čo vedie k smrti tejto bunky. Aby sme nepoškodzovali okolité zdravé tkanivo (ako je koža alebo orgány), lúče sú namierené z niekoľkých uhlov, aby sa pretínali v mieste nádoru. Nádorová bunka týmto spôsobom dostane oveľa väčšiu absorbovanú dávku žiarenia než okolité zdravé tkanivo. Na rozdiel od chemoterapie, ktorá pôsobí na nádorové bunky po celom tele (v prípade metastáz), rádioterapia zasahuje iba to miesto v tele, kde je nádor. [4,7]

Rádioterapia sa vykonáva 2 základnými spôsobmi:

- **Telerádioterapia** je častejšie využívanou metódou, ktorá nádor ožaruje mimo tela pacienta cez kožu. Využíva sa brzdné žiarenie lineárneho urýchľovača. Výhodou je možnosť voľby rôznej energie žiarenia podľa uloženia nádoru.
- **Brachyterapia:** zdroj žiarenia je umiestnený do tesnej blízkosti ložiska alebo priamo do pôvodného miesta nádoru. To umožňuje lokálne aplikovať väčšiu dávku v kratšom čase. Využíva sa pri liečbe gynekologických nádorov (krčka maternice, maternice, vonkajších rodidiel), zažívacieho traktu (pažeráka, žlčových ciest, konečníka) a na liečbu nádorov prostaty. [7]

Rádioterapiu je potrebné vopred naplánovať na simulátore, ktorý napodobňuje reálne ožarovanie. Následne nádorové ložisko zobrazíme pomocou počítačového tomografu (CT) prípadne pomocou MRI a na telo pacienta sa nakreslia značky, ktoré umožňujú lokalizovať nádor pri ožarovaní. Existuje mnoho pomôcok na fixáciu polohy pacienta, ako napríklad masky či vankúše. [4]


Následne sa vyberie vhodný program ožarovania - zvolí sa smer a druh žiarenia, energia a potrebný počet dávok. Tieto parametre závisia od typu a veľkosti nádoru, jeho umiestenia, štádia a taktiež na celkovom zdravotnom stave pacienta. [4]

Špeciálnym druhom je takzvaná stereotaktická rádioterapia tela (napr. CyberKnife), pri ktorej sa využíva žiarenie vysokých dávok dodávané pomocou robotického navádzania.

Pomerne nová ožarovacia metóda v liečbe rakoviny je protónová terapia, ktorá dokáže dosiahnuť nielen vyššiu účinnosť, ale predovšetkým sa vyznačuje menším poškodením zdravých tkanív. Využíva fyzikálne vlastnosti protónov, menovite ich väčšia razancia pri priepustnosti tkanivami (viac než 200 MeV). Na rozdiel od štandardnej rádioterapie sa pri protónovej terapii môže meniť smer a sklon žiarenia, čo umožňuje ochrániť orgány blízko nádoru. [4,5, 7]

1.2 Chemoterapia

Chemoterapia je typ liečby rakoviny, ktorá využíva chemické látky na liečbu nádorových ochorení. Cytostatiká sú lieky, ktoré pôsobia toxicky na nádorové bunky, čiže ich cieľom je zastaviť mitózu (delenie) nádorových buniek a spôsobiť na ich apoptózu, čiže zánik. Schematický opis princípu chemoterapie nájdeme na obrázku 1. Chemoterapia sa zameriava na bunky, ktoré rýchlo rastú a delia sa, čo je vlastnosťou najmä rakovinových buniek. Ovplyvňuje však aj niektoré rýchlo rastúce zdravé bunky, napríklad bunky kože, tráviaceho traktu, vlasové folikuly či bunky kostnej drene, čo spôsobuje vedľajšie účinky liečby. Bližšie sa oboznámime s vedľajšími účinkami v podkapitole 1.3 [6,7,8]



Obrázok 1: Princíp chemoterapie [zdroj: <https://www.healthdirect.gov.au/chemotherapy> + vlastná úprava]

Na rozdiel od ožarovania alebo chirurgického zákroku, ktoré sa zameriavajú na konkrétne oblasti, chemoterapia môže pôsobiť na akúkoľvek anatomickú oblasť v tele, pretože je prenášaná krvným obehom.

Existuje niekoľko možností podania cytostatík:

- **Injekcia** : priamo do svalu v oblasti bedra, stehna alebo ramena alebo do tukovej časti ramena, nohy alebo žalúdka;
- **Intraarteriálne**: cez ihlu alebo katéter do tepny,
- **Intravenózne**: do žíl pomocou infúznej pumpy alebo katétru;
- **Intraperitoneálne**: do peritoneálnej dutiny: pečeň , črevá , žalúdok a vaječníky . Uskutočňuje sa počas chirurgického zákroku alebo pomocou katétru zavedeného do špeciálneho portu, zavedeného lekárom,
- **Orálne**: vo forme tablety alebo tekutiny (napr. melfalan, busulfán, kepecitabín).

Najčastejšie používané cytostatiká radíme alkylačné látky, ktoré poškadzujú štruktúru nukleových kyselín nádorových buniek či antimetaboly, ktoré nahrádzajú látky dôležité pri tvorbe DNA a RNA, avšak ich pôsobením je vzniknutá štruktúra odsúdená na zánik. Ďalšou alternatívou je použitie cytotoxických antibiotík, ktoré poškadzujú fungovanie DNA nádorových buniek. Antimitotiká,

ako už z názvu vyplýva, bránia nádorovej bunke v delení. Medzi najznámejšie antimitotiká patria vinkristín alebo vinblastín. [8,9]

Prídavné lieky, ktorých hlavnou úlohou je zvýšenie účinnosti cytostatík sú steroidy (napr. dexametazón). Sú dôležité na potláčanie reakcií imunitného systému a zníženie hladiny cytokínov, ktoré sú zodpovedné za tvorbu nechcených zápalov. V závislosti na osobe, rakovine, štádiu rakoviny, druhu chemoterapie a dávkovaní sa môže intravenózna chemoterapia podávať buď stacionárne alebo ambulantne. Pri dlhodobom alebo kontinuálnom dávkovaní sa používajú chirurgicky zavedené vaskulárne prístupové zariadenie. Vďaka tomuto prístupu na vnútro žilové podávanie cytostatík sa znižuje riziko vzniku infekcie, flebitídy a extravazácie. [8,9]

Chemoterapia predstavuje systémové liečenie rakoviny, pretože sa zavádza do krvného obehu a preto dokáže liečiť rakovinu v ktoromkoľvek anatomickom mieste tela. Môže byť podávaná samostatne (pri leukémii a rakovín lymfatického systému), avšak častejšie je využívaná v kombinácii s chirurgickým odstránením nádoru prípadne s rádioterapiou. Adjuvantná chemoterapia, je liečba, ktorá sa podáva po hlavnom zákroku. Je dôležitá na zabránenie vzniku ďalších metastáz. Keď je chemoterapia podávaná pred zákrokom (neoadjuvantná chemoterapia), očakávame od nej zlepšenie účinku ďalšej liečby. Chemoterapia môže byť podávaná ako paliatívna liečba u neliečiteľných ochorení, kedy predlžuje život aj o niekoľko mesiacov. [7,8,9]

Chemoterapia je naplánovaná na niekoľko cyklov, ktoré sú koncipované tak, aby dosiahli najväčší účinok pri zabíjaní nádorových buniek s ohľadom na čas potrebný na regeneráciu zdravých buniek. Liečebné cykly sa aplikujú každé 3-4 týždne, v závislosti na type a štádiu rakoviny. Liečebné cykly zvyčajne trvajú až 6 mesiacov. [8]

1.3 Nežiadúce zmeny na tele pacienta pri rádioterapii a chemoterapii

Bohužiaľ, žiarenie zasahuje a poškodzuje aj zdravé bunky citlivé na žiarenie, čím sa môže negatívne ovplyvniť ich funkcia. Pri prechode lúčov žiarenia tkanivami, tieto lúče strácajú svoju energiu a do samotného nádoru dorazí teda iba časť vyslaného žiarenia.

Pravdepodobnosť vzniku vedľajších účinkov je do veľkej miery daná rozdelením dávky do určitého počtu frakcií, ošetrovaným miestom a prípadnými existujúcimi komorbiditami. [4,10]

Toxicitu môžeme rozdeliť:

- **Včasná toxicita:** vo všeobecnosti reverzibilná, musí sa však vhodne liečiť. Začína asi dva týždne po liečbe, ale príznaky majú tendenciu vyvrcholiť dva až štyri týždne po ukončení liečby.
- **Neskorá toxicita:** vyskytuje sa najmenej šesť mesiacov po liečbe ale môže sa prejaviť po niekoľkých rokoch. Neskorá toxicita je často nezvratná. [4]

Rádioterapia:

Na toxické účinky rádioterapie sú najcitlivejšie rýchlo sa množiace tkanivá - napr. pokožka, sliznice a kostná dreň. [4]

1.3.1 Akútne vedľajšie účinky pri rádioterapii

Akútne účinky sú definované ako vyskytujúce sa počas liečby a do 2 - 3 týždňov po jej ukončení. Tieto vedľajšie účinky majú tendenciu sa zmiernovať.

- **Všeobecná únava:**

- je najbežnejším akútnym nepriaznivým účinkom (vyskytuje asi u 80% pacientov liečených rádioterapiou);
- má tendenciu vrcholiť v druhom týždni a zlepšuje sa asi 4 týždne po ukončení liečby. [10,11]

- **Koža:**

- vyskytuje sa erytém, suché a vlhké deskvamácie, spaľovanie pokožky, vypadávanie vlasov a dysfunkcia mazových žliaz,
- v prípade, že sa na pokožke vyskytujú vlhké deskvamácie, musí sa udržiavať prísne čistá, aby sa zabránilo superinfekcii,
- koža sa hojí od vonkajších okrajov smerom dovnútra asi 3 týždne,
- k vypadávaniu vlasov dochádza v čase liečby, ale je zvyčajne dočasné a vlasy znovu začínajú rásť v priebehu niekoľkých týždňov po ukončení liečby,
- chemoterapeutické látky môžu zvyšovať citlivosť pokožky. [12,13]

- **Gastrointestinálny trakt:**

- strata chuti, dysfunkcia slín, orálna mukozitída, hnačka, nevoľnosť a zvracanie (u 50 - 80% pacientov),
- závažná, bolestivá mukozitída môže byť komplikovaná kvasinkovou alebo bakteriálnou superinfekciou a preto by sa mali používať antimikrobiálne látky. [14]

- **Kostná dreň:**

- pri ožarovaní celého tela počet bielych krviniek klesá, čím sa znižuje imunita. [4]

- **Pľúca:**

- ožarovanie pľúc môže spôsobiť pneumonitídu s horúčkami, kašľom, dýchavičnosťou a pľúcnyimi infiltrátmi. [17]

1.3.2 Chronické vedľajšie účinky pri rádioterapii

Dlhodobé komplikácie sa zvyčajne vyskytujú pri prekročení tolerancie tkanív. Aby sme zabránili alebo aspoň zredukovali tieto komplikácie, je nevyhnutná dôkladná dozimetria a plánovanie. [4]

- **Komplikácie v oblasti hlavy:**

- vysoká dávka môže viesť k fibróze v oblasti krku a zníženiu pohybu s drevitou textúrou,
- fibróza v oblasti čeľuste zhoršujúca žuvanie (pooperačné cviky na podporu čeľustných svalov môžu túto komplikáciu zmierniť),
- strata slinného toku pri xerostómii najmä po ožarovaní v oblasti hlavy alebo krku (vzniká dôsledkom ožarovania príušných ciev)
- atrofia a teleangiektázy orálneho a gingiválneho tkaniva,
- katarakta, syndróm suchého oka, retinitída,
- zápal stredného ucha alebo senzorineurálna strata sluchu. [10,11]

- **Koža:**
 - oneskorené hojenie rán,
 - telangiektázy - trvalé rozšírenie kapilár na koži v podobe červených nitiek,
 - ulcerácia nad kosťou s expozíciou a možnou osteoradionekrózou (je našťastie zriedkavá). [12,13]
- **Lymfatický systém:**
 - lymfedém, prerušovaný eryzipel. [11]
- **Pohlavný systém:**
 - neplodnosť - vysoké dávky žiarenia počas tehotenstva môžu spôsobiť rôzne anomálie a mentálne postihnutie dieťaťa. [16]
- **Centrálny nervový systém:**
 - ožarovanie miechy môže spôsobiť priečnu myelitídu a Lhermittov fenomén (pocit pri predklone krku podobný elektrickému šoku),
 - úplná priečna myelitída s Brownovým-Séquardovým syndrómom (je našťastie zriedkavá),
 - zvýšené riziko vzniku náhlych srdcovocievnych príhod či mŕtvice. [11,15]

Medzi možnosti ochrany pred žiarením patria látky, ktoré poznáme pod názvom rádioprotektory. „Rádioprotektory sú zlúčeniny, ktoré zvyšujú rezistenciu živého tkaniva pred účinkami ionizujúceho žiarenia, a tým dochádza k nárastu tolerancie organizmu voči účinkom žiarenia. Spoločnou vlastnosťou väčšiny rádioprotektívnych látok je schopnosť zbavovať bunku voľných radikálov.“ [17]

Chemoterapia:

Toxicita chemoterapie značne závisí od typu použitých liekov. Najčastejšie lieky vplývajú na funkciu rýchlo sa deliacich buniek tela, ako sú bunky sliznice úst, žalúdka a čriev a krvinky. [8]

1.3.3 Vedľajšie účinky pri chemoterapii

- **Imunitný systém:**
 - väčšina cytostatík spôsobuje imunosupresiu, spôsobenou znížením bielych krviniek ale aj ostatných krvných zložiek,
 - môže sa prejavíť anémia, ktorú sprevádza únava a bledosť,
 - myelosupresia, pri ktorej sú ničené kmeňové bunky kostnej drene (môže dôjsť až k nevyhnutnosti transplantácie kostnej drene),
 - reakcie na znížený imunitný systém: sepsa, herpes simplex, pásový opar a pod. ,
 - modriny, problémy s krvácaním a zo zrážaním krvi, kvôli zníženej hladine krvných doštičiek. [8,18]
- **Gastrointestinálny systém:**
 - nevoľnosť, zvracanie, anorexia, hnačky, kŕče v bruchu zápcha,
 - neutropenická enterokolitída (tyfitída), ktorá je charakterizovaná ako nekrotizujúci zápal čreva,
 - bolesti v ústnej dutine, sucho v ústach. [8]

- **Koža:**
 - strata vlasov (alopécia) je zvyčajne dočasná komplikácia. Po ukončení liečby sa začínajú obnovovať (viď obrázok 2), avšak často v inej štruktúre, farbe či hrúbke.



Obrázok 2: Obnova vlasov po chemoterapii

[zdroj: <https://nationalhairlossassoc.com/cancer-related-hair-loss/> + vlastná úprava]

- **Nervový systém:**
 - periférna neuropatia – nedostatočné reakcie v prstoch na rukách a nohách, bolesť, mravčenie, znecitlivenie alebo slabosť svalov,
 - kognitívne poruchy, ako napr. neschopnosť sústrediť sa. [8,15,18]
- **Pohlavný systém:**
 - predčasné zlyhanie vaječníkov a strata primordiálnych folikulov, čo spôsobuje neplodnosť u žien,
 - teratogenita najmä počas prvého trimestra, odporúčaný je potrat. [16]
- **Poškodenie ostatných orgánov:**
 - kardiotoxicita (poškodenie srdca) v dôsledku vzniku voľných radikálov,
 - hepatotoxicita (poškodenie pečene),
 - nefrotoxicita (poškodenie obličiek),
 - ototoxicita (poškodenie vnútorného ucha) je častým vedľajším účinkom. [18,19]

V tejto diplomovej práci sa zameriame hlavne na vonkajšie kontraindikácie pri podstupovaní onkologickej liečby, keďže hlavne tieto príznaky nám významne ovplyvňujú ich biometrickú identifikáciu.

2 Princípy biometrickej identifikácie na základe analýzy obrazu

2.1 Biometrická identifikácia

Pod pojmom biometrická identifikácia rozumieme proces, pri ktorom sa jednoznačne určí identita človeka na základe jedného alebo viacerých rozlišujúcich znakov, ktoré sú pre každého jedinca jedinečné. Medzi najčastejšie používané identifikátory môžeme zaradiť napríklad tvár, dúhovku, odtlačok prsta, hlas, dlaň, krvné riečište atď. Každá biometrická charakteristika má svoje výhody aj nevýhody, preto je dôležité posúdenie na aký účel má byť systém biometrickej identifikácie určený. [20]

Používanie biometrie v súčasnosti stále rastie, keďže ponúka automatickú, pomerne rýchlu a presnú metódu na rozpoznávanie jedincov. Záujem o tento druh identifikácie narastá aj vzhľadom na stále sa zvyšujúce nároky na bezpečnosť budov či jednotlivých pracovísk. S biometrickou identifikáciou sa stretávame v mobilných zariadeniach, kde je využívaný odtlačok prstu a rozpoznávanie tváre, na hraniciach v podobe biometrických brán, na letiskách pri odbavovaní cestujúcich, v bankovníctve či pri vstupe do historických pamiatok. [20]

2.2 Základné pojmy


Na začiatok je nutné objasniť si jednotlivé pojmy, ktoré sú dôležité na pochopenie tejto problematiky.

Biometria: metóda, založená na rozpoznávaní človeka na základe jedinečných vonkajších charakteristík.

Identita: udáva totožnosť každého jedinca.

Identifikácia: je proces, ktorého cieľom je určiť identitu človeka. Je založený na porovnávaní nasnímanej vzorky so všetkými referenčnými šablónami, ktoré sa v databáze nachádzajú. Zjednodušený vzorec tohto procesu je „jeden k viacerým“.

Verifikácia: je proces, ktorého cieľom je overiť identitu. Je založený na porovnávaní nasnímanej vzorky s jednou referenčnou šablónou. Zjednodušený vzorec tohto procesu je „jeden k jednému“. Rozdiel medzi verifikáciou a identifikáciou nájdeme na obrázku 3. [20,21,22]



Obrázok 3: Rozdiel medzi identifikáciou a verifikáciou [zdroj: autorka]

2.3 Princíp biometrického systému

Proces biometrickej identifikácie je zložený z niekoľkých krokov, ktoré spadajú do dvoch hlavných fáz:

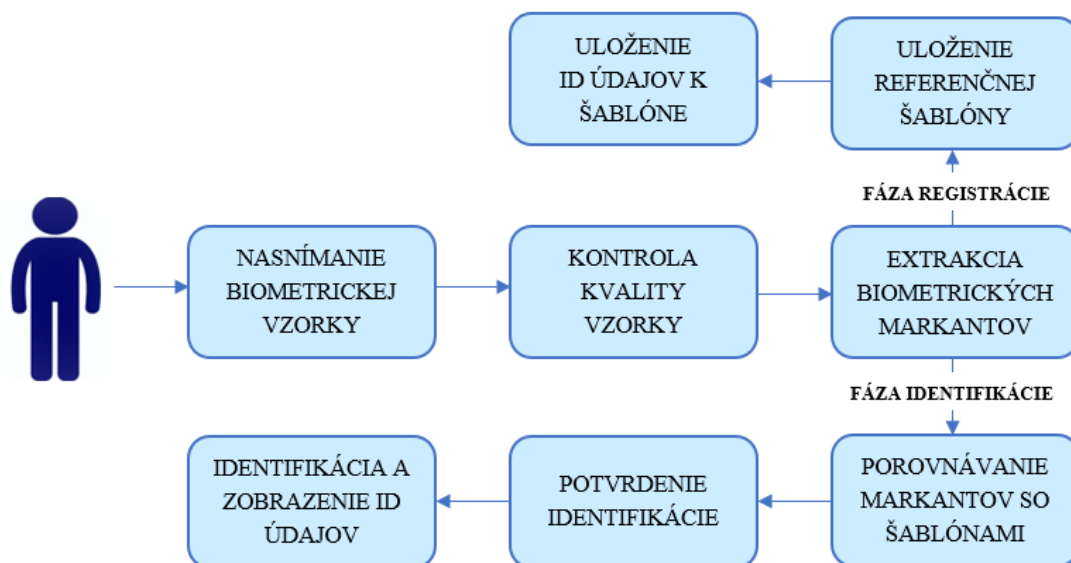
- **Fáza registrácie:** získava sa referenčná šablóna (etalón) používateľa a jeho jedinečných charakteristických črt. Následne sa šablóna uloží do databázy pod určitým ID alebo priamo menom používateľa. Šablóna sa môže uložiť buď do biometrického čítacieho zariadenia alebo vzdialenej centrálnej databázy.
- **Fáza identifikácie:** porovnanie novozískaných vzoriek so šablónami, uloženými v databázy. [21]

Biometrický systém pracuje na základe porovnávania získaných jedinečných biometrických charakteristík s predom získanými šablónami. Najskôr je pomocou snímača zachytená biometrická vzorka, ktorá zachytáva jedinečné biometrické charakteristiky. Snímač môže byť videokamera, snímač odtlačku prsta prípadne iný senzor, ktorý je určený na snímanie vybranej charakteristiky. Po získaní potrebnej biometrickej vzorky je potrebné overiť, či je vzorka nasnímaná v dostatočnej kvalite, tak aby bol pripravený na ďalšie spracovanie. Pri nekvalitnej vzorke, na ktorej nie je možná identifikácia, je nutné snímanie opakovať. [21; 22]

Merateľné údaje zo získanej biometrickej vzorky poznáme pod pojmom biometrické markanty. Pri identifikácii pomocou tváre môžu byť biometrické markanty napríklad kútky úst, konce očí atď. Extrakcia jednotlivých markantov je založená na maticovom algoritme, v ktorom si výrobca biometrického systému určí, ktoré merateľné vlastnosti pri identifikácii využije. Súbor biometrických markantov z jednej vzorky sa uloží do databázy ako referenčná šablóna s jedinečným ID alebo menom. Referenčná šablóna slúži na jednoznačnú identifikáciu používateľa pri jeho identifikácii. Dátová veľkosť referenčnej šablóny je podstatne menšia ako veľkosť biometrickej vzorky. [21; 22]

Pokiaľ systém pracuje vo fáze identifikácie, tak po extrakcii biometrických markantov už nenastáva ukladanie šablóny (keďže tento proces už u snímanej osoby pravdepodobne prebehol). Namiesto toho prebieha porovnávanie biometrických markantov s jednou alebo viacerými šablónami, ktorá je uložená v databáze a na základe koeficientu podobnosti rozhoduje o jednotlivých biometrických markantoch. Pokiaľ ide o verifikáciu, systém na základe koeficientu podobnosti zamietne alebo potvrdí prístup. Biometrický systém určený na identifikáciu postupne overuje všetky šablóny v databáze, až kým nájde šablónu s koeficientom podobnosti 1. Proces identifikácie je preto zdĺhavejší ako proces verifikácie, preto sa referenčné šablóny triedia do podkategórií aby sme dostali výsledok čo najrýchlejšie. [20,21,23]

Celý princíp biometrickej identifikácie popísaný vyššie, nájdeme v prehľadnej schéme na obrázku č.4.



Obrázok 4: Proces systému biometrickej identifikácie [zdroj: autorka]

2.4 Základné vlastnosti biometrického systému

Vhodnosť biometrického systému na konkrétne použitie posudzujeme podľa niekoľkých základných vlastností:

- **Jedinečnosť:** vyjadruje, s akou šancou je možné nájsť a následne úspešne rozpoznať dve osoby, ktoré majú rovnaké alebo podobné rysy. Čím je táto šanca nižšia tým je systém presnejší.
- **Konštantnosť:** nemennosť v čase. Najlepšie spĺňa túto vlastnosť identifikácia pomocou dúhovky alebo sietnice, pretože tie sa začínajú vyvíjať už v 22. týždni embryonálneho vývoja a v priebehu veku sa nemenia.
- **Získateľnosť:** biometrická charakteristika musí byť merateľná a symbolicky vyjadriteľná.
- **Finančné náklady:** náklady spojené so zaobstaraním snímača a použitia hardwarových a softwarových komponentov.
- **Praktickosť:** tento faktor určuje, ako musí užívateľ zasahovať do systému identifikácie a aký dlhý čas identifikácia trvá. V tomto smere sú výhodnejšie bezkontaktné metódy.
- **Odolnosť:** miera imunity proti falšovaniu; či už softwarového alebo vnútenie inej biometrickej charakteristiky (umelý odtlačok prstu, fotografia namiesto reálnej tváre atď).
- **Univerzálnosť:** charakteristika je možná merať u čo najväčšej populácie. Biometrická metóda musí byť prijateľná z aspektov náboženských, osobných, etických, politických či sociálnych.
- **Spôľahlivosť:** Výsledok by mal byť vždy rovnaký za rôznych svetelných či klimatických podmienok.

Algoritmus biometrickej identifikácie spočíva hlavne v snímaní, kódovaní, kompresii, prenášaní a dekompresii dát. Môžeme rozlišovať bezpečné a spoľahlivé. Absolútna bezpečnosť existuje len v teoretickej rovine v praxi sa počíta s vypočítateľnou mierou rizika. [21; 28]

V tabuľke 1 nájdeme porovnanie jednotlivých biometrických charakteristík a ich vlastností.

Tabuľka 1: Základné vlastnosti vybraných biometrických metód [zdroj: 27; 28 - vlastná úprava]

Biometrická metóda	Princíp snímania	Jedinečnosť	Konštantnosť	Získateľnosť	Finančné náklady	Odolnosť
Odtlačok prsta	Optické/kapacitné	1:1 000 000	Veľmi dobrá	Stredná	Nízke	Vysoká
Tvár	Optické/ infračervené	1:5000	Dobrá	Vysoká	Vysoké	Nízka
Očná dúhovka	Optické	1:6 000 000	Veľmi dobrá	Stredná	Vysoké	Vysoká
Geometria ruky	Optické/ infračervené	1:10 000	Dobrá	Vysoká	Stredné	Stredná
Žily na dlani	Infračervené	1:12 500	Dobrá	Stredná	Stredné	Vysoká

2.5 Biometrické charakteristiky

Na biometrickú identifikáciu sú používané najrôznejšie charakteristiky, ktoré sa posudzujú podľa vhodnosti na konkrétny účel. Nie je však možné vybrať si ktorúkoľvek vlastnosť človeka a rozhodnúť sa, že toto bude môj identifikátor. Biometrické charakteristiky musia spĺňať určité kritériá, aby bolo možné identifikáciu použiť. [21]

Medzi najhlavnejšie pravidlá patria univerzálnosť a unikátnosť. Každý človek by mal mať skúmanú charakteristiku a pre každého jedinca by mala byť táto charakteristika jedinečná, aby bolo možné človeka identifikovať s vysokou spoľahlivosťou a presnosťou. Jednou z charakteristík je aj časová nemennosť znakov, ktorá je obzvlášť dôležitá pri našom použití, kde sa veľmi veľa charakteristických znakov onkologických pacientov po podstupovaní liečby mení. Samozrejmosťou je merateľnosť danej charakteristiky tak, aby jednotlivcovi nespôsobovala zbytočné nepríjemnosti a aby bola prijateľná pre všetky skupiny ľudí bez náznaku akejkoľvek diskriminácie. Celý proces biometrickej identifikácie musí byť dostatočne spoľahlivý a výsledok by mal byť vždy rovnaký aj s vplyvom rozdielných okolitých podmienok. [20, 24]


Neexistuje ideálna biometrická charakteristika, ktorá by spĺňala všetky uvedené vlastnosti avšak je možné posúdiť, ktorá je pre danú aplikáciu najvhodnejšia.

2.5.1 Odtlačok prsta

Biometrická identifikácia pomocou odtlačku prsta je najrozšírenejšou metódou k identifikácii osôb. Na snímanie sa využívajú papilárne línie, vytvorené v embryonálnom vývoji každého človeka. Tieto vyvýšeniny povrchovej štruktúry sú pre každú osobu ale aj pre každý prst jedinečné. Povrch prstov tvorí rôzne tvary a jedinečné vzory. Najrozšírenejším tvarom povrchových štruktúr sú smyčky, ktoré sa vyskytujú až u 65% populácie, nasledujú oblúky, ktoré nájdeme v 35% všetkých odtlačkov. [25]

Daktyloskopia predstavuje extrakciu markantov (na odtlačku prsta ich je možné detekovať 75-175 markantov). Medzi biometrické markanty odtlačku prsta radíme rôzne háčiky, očka, vidlice, mostíky, skríženiny atď. (viď obrázok 5). Aby sme mohli odtlačok považovať za zhodný s referenčnou

šablónou musí byť zhodnosť v 12-15 markantoch. Je pri tom nutné počítať s faktom, že pokožka je neustále zvlhčená potom. [25]



Obrázok 5: Druhy markantov otlačkov prsta [zdroj: 25; str.33]

Medzi kontaktné snímače patrí **optoelektronický senzor**, ktorý pracuje na základe odrazu a rozptylu svetla. Maticový CCD detektor osvetlí celú plochu prsta a následne odrazené svetlo prejde cez luminoforovú vrstvu a späť a vytvorí sa obraz. Optoelektronický snímač sa vyznačuje vysokou odolnosťou a kvalitou čítania, ale kvôli väčším rozmerom je komplikované ho aplikovať do prenosných zariadení. [21]

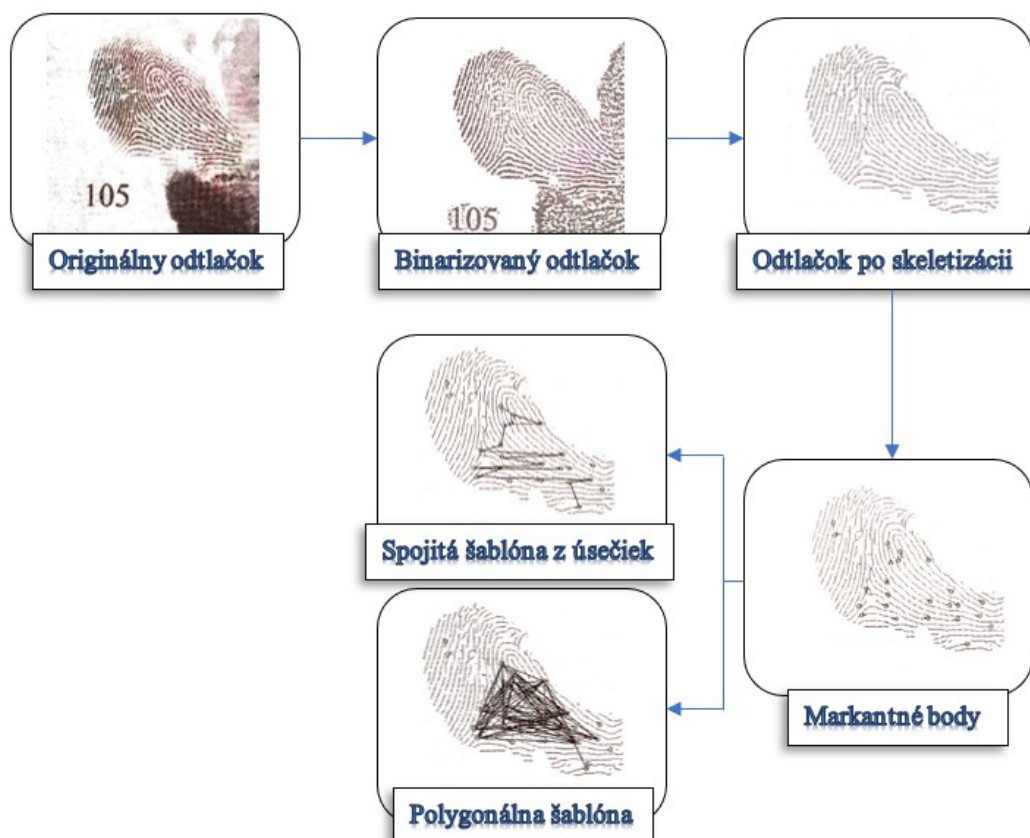
Najpoužívanejší kontaktný biometrický snímač patrí **kapacitný senzor**, ktorý nájdeme aj na smart telefónoch. Zmena dielektrika medzi jednou doskou kondenzátora (vodivej vrstvy) a druhou doskou (prsta) vytvára rôzne veľké elektrické pole, ktorého veľkosť meriame. Tento typ snímaču je najpresnejší a jeho rozmer je veľmi malý. Ďalšie kontaktné snímače, ktoré používajú známe fyzikálne princípy sú napríklad teplotné snímače, tlakové snímače, elektroluminiscenčné snímače či multispektrálne snímače. [21,24]

U bezkontaktných snímačov sa využíva najmä optika a ultrazvuk. Princíp optického snímača je podobný ako u optických kontaktných, avšak prst je snímaný zo vzdialenosti 30 až 50mm. U ultrazvukových snímačov sa používajú zvukové vlny a ich odraz od povrchu prsta. Tento typ sa využíva tam, kde je predpoklad, že ľudia budú mať znečistené ruky a preto druh snímača vyžaduje vyššie finančné prostriedky. [21, 23]

Princíp spracovania obrazu odtlačku prsta:

Na úvod celého procesu získavania odtlačkov je potrebné použiť snímač, ktorý ovplyvňuje kvalitu obrazu a množstvo šumu. Štandardná hodnota rozlíšenia odtlačku prstu je 500 dpi. Celý tento proces nazývame **digitalizácia obrazu**. Následne sa obraz **filtruje** tak, aby bolo možné identifikovať typické markantné body. Zvýšením kontrastu obrazu (zvyčajne pomocou adaptívneho prahovania) docielime zvýraznenie papilárnych línií a odstránime nadbytočný šum. Ďalšou fázou spracovania obrazu je **binarizácia**, čiže prevedenie originálneho obrazu v 256 stupňoch šedej do binárneho zobrazenia. Čierna farba v binárnom obraze predstavuje papilárne línie, naopak biela farba medzery medzi ryhami. Vo vytvorenom binárnom obraze je detekcia hrán a charakteristických bodov výrazne jednoduchšia. Papilárne línie v binárnom obraze sú širšie ako 1 pixel, keďže nastáva duplicita bodov spôsobená rozvetkovaním alebo ukončením hrubých línií. Kvôli tomu je potrebná tzv. skeletizácia, čo je technika predspracovania obrazu, ktorá stenčí papilárne línie na jeden pixel. [2,21, 24]

Extrakčné algoritmy v predspracovanom obraze vylučujú zle čitateľné markanty a každému správne biometrickému markantu priradujú informácie o type, orientácii (uhol Θ) a súradniciach ($s=[x;y]$). Tieto informácie redukujú dáta pre zápis do databázy. Následne je vytvorená šablóna odtlačku prsta pomocou prepájania markantných bodov, čiže **vizualizácie**. Body môžeme spájať do úsečiek alebo polygónov. Celý proces spracovania odtlačku prsta je názorne zobrazený na obrázku 6. Pripravená šablóna sa uloží do databázy ako referenčná alebo je pripravená k porovnávaniu. [21]



Obrázok 6: Proces spracovania odtlačku prsta [zdroj: 27; str. 226-229 + vlastná úprava]


2.5.2 Tvár

Poznáme dva spôsoby identifikácie podľa tváre: geometrický a fotometrický. Biometrická identifikácia na základe tvárových rysov je založená na porovnávaní snímky vytvorenej kamerou a snímky uloženej v databáze. Na tvári sa vyznačia charakteristické body, spoja sa úsečkami a zmeria sa dĺžka týchto úsečiek. Podľa pomerov úsečiek sa rozozná tvár. [21,25]

Úsečky aplikujeme na tieto miesta na tvári:

- spojenie ušného laloku a tváre,
- body na ušnej chrupavke chrániace zvukovod,
- prechod nosu do čela,
- uhol medzi špičkou nosa a okom,
- vnútorné a vonkajšie kútiky očí,
- horizontálne kútiky pier,
- horná pera a nos a pod. .

Tvář obsahuje cca 80 typických rysů. Na správnou identifikaci by malo stačiť rozpoznať 12-18 z nich. Všeobecné antropologické body vyznačené na ľudskej tvári môžeme nájsť na obrázku 7. Možný problém identifikácie pomocou tváre patria nepresnosti pri porovnávaní snímky s iným uhlom, za iných svetelných podmienok atď. Na zvýšenie kvality a bezpečnosti rozpoznania sa využíva sa napríklad trojité snímkovanie v 3 rôznych vzdialenostiach od kamery. Taktiež existujú 3D snímače, ktoré používajú dvojicu kamier a snímajú tvár z rôznych uhlov, prípadne snímače s jednou kamerou v jednom uhle, využívajúce jemnú mriežku. [21,24,27]



Obrázok 7: Všeobecné antropologické body [zdroj: 27; str. 308]

Princíp spracovania obrazu tváre:

Najznámejšie a najviac používané algoritmy na rozpoznávanie tváre sú:

- **Lineárna diskriminačná analýza (LDA - Linear Discriminant Analysis)**

LDA je algoritmus, ktorý zoradí nasnímané snímky do skupín a tried. Tento proces slúži najmä na zvýšenie rozdielov medzi jednotlivými skupinami a zníženie rozdielov v jednej skupine.

- **Analýza hlavných komponent (PCA - Principal Components Analysis)**

Algoritmus PCA najskôr vytvára kovariačnú maticu pravdepodobnostnej distribučnej funkcie z ktorej odvodíme vektory. Zo vzniknutých vektorov má vznikne referenčná šablóna, ktorú uložíme do databázy a tým je pripravená na porovnávanie. Výhodou je, že každú snímku môžeme rozložiť do matice jasových úrovní a naspäť zložiť, čiže do databázy sa ukladajú iba čísla jasových úrovní, čím znižujeme redundáciu dát.

- **Elastický porovnávací diagram (EBGM - Elastic bunch graph matching)**

EBGM využíva súradnicovú sieť tváre, ktorá je vytvorená pospájaním uzlových bodov. Narozdiel od predošlých algoritmov EBGM zohľadňuje aj nelineárne charakteristiky ako je výraz tváre, osvetlenie či pozícia hlavy. Pokiaľ chceme dosiahnuť lepšiu lokalizáciu orientačných bodov je možné tento algoritmus kombinovať s predošlými dvoma algoritmami. [2, 3, 22]

2.5.3 Dúhovka oka

Patrí medzi najpresnejšie metódy identifikácii, keďže každá dúhovka je úplne odlišná, dokonca aj u jednovaječných dvojčiat nájdeme rozličnosti v dúhovke. Šanca, že nájdeme dva identické odtlačky prstov je 1050 krát väčšia, ako to, že nájdeme dve rovnaké dúhovky (pravdepodobnosť nájdania rovnakých dúhoviek je až $1:10^{52}$). [26; str. 3] Veľkou výhodou je aj fakt, že sa dúhovka v priebehu života nemení.

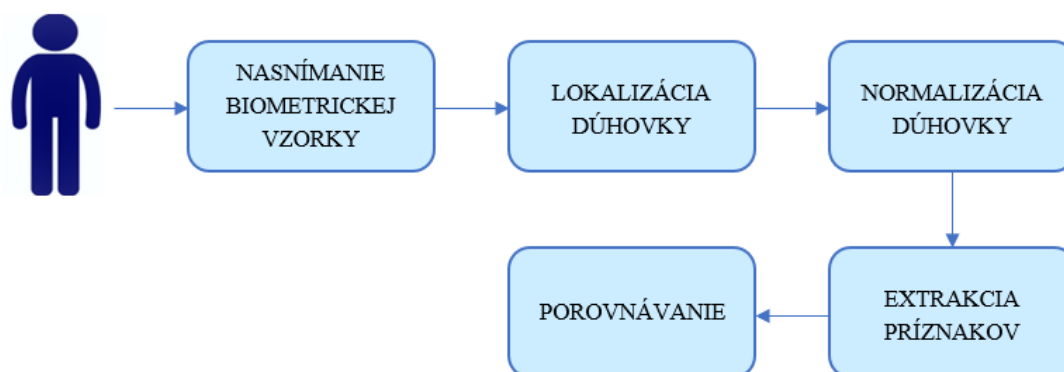
Na očnej dúhovke môžeme nájsť približne 250 rysov, z ktorých na identifikáciu najčastejšie používame tieto:

- krypty: tmavé miesta, kde je dúhovka najtenšia,
- pigmentové škvrny: pigmentové zhluky,
- radiálne ryhy: začínajú blízko šošovky a lúčovite vybiehajú k okraji dúhovky,
- pigmentové záhyby: vystupujúce spodné vrstvy v blízkosti zornice. [20,21]

Ako bezkontaktný snímač dúhovky sa väčšinou používa kamera, ktorá pracuje na vlnovej dĺžke 700 až 900nm. Pre používateľa je infračervené svetlo príjemnejšie, pretože neosľuže. Na vylepšenie snímania sa k digitálnej kamere pridáva externý zdroj svetla, prípadne sa používa väčší počet kamier. Dôležitou súčasťou identifikačného systému dúhovky je overenie, či sa jedná o živé oko a nie len fotka či obrázok. [20,26]

Princíp spracovania dúhovky:

Spracovanie snímku očnej dúhovky začína prevedením farebných odtieňov do stupňov šedej, čím sa zredukujú odchýlky farebných tónov, ktoré vznikli zlým nasvietením alebo kvôli nepresnostiam CCD snímačov. Následne sa vykoná segmentácia, ktorá určí polohu dúhovky a šošovky a ich vonkajšie a vnútorné hranice. V tomto kroku sa využíva Sobelov a Cannyho detektor hrán. Po segmentácii potrebné vykonať normalizáciu, tak aby boli snímky dúhovky rovnakej veľkosti. Rozdielne veľkosti nasnímaných dúhoviek vznikajú napríklad kvôli rôznej vzdialenosti od snímača. Ďalším krokom je zmena kartézskych súradníc na polárne, čo znamená, že dúhovka v tvare medzikružia je prevedená na obdĺžnikový tvar, na ktorom určíme súradnice polomerov a uhlov. Posledným krokom je extrakcia a porovnanie extrahovaných príznakov so šablónami. Na extrakciu dúhovky môžu byť použité 4 algoritmy: Wavelet features (Vlnkové rysy), Daugmanov algoritmus, Analýza nezávislých komponent alebo Variácia lokálnych kľúčov. Blokovú schému procesu spracovania dúhovky nájdeme na obrázku 8. [2,21; 22; 26]



Obrázok 8: Proces spracovania snímky dúhovky

[zdroj: https://www.vutbr.cz/www_base/zav_prace_soubor_verejne.php?file_id=209837; str.19 + vlastná úprava]

2.5.4 Ostatné biometrické charakteristiky

Medzi ďalšie biometrické charakteristiky patrí napríklad snímanie očnej sietnice, či snímanie geometrie ruky. Princíp snímania sietnice spočíva v presvecovaní štruktúry obrazu v okolí slepej škvŕny LED diódou s infračerveným svetlom nízkej intenzity. Snímanie geometrie ruky overuje dĺžku a šírku prstov a ruky pomocou naskenovanej 3D fotografie prevedenej do 9 bytovej hodnoty. Obe tieto metódy sa prioritne využívajú na verifikáciu, avšak nie na identifikáciu. Identifikácia osoby je možná aj pomocou hlasu či spôsobu chôdze. Obe biometrické charakteristiky sú veľmi ovplyvniteľné viacerými faktormi a nepatria medzi najpresnejšie metódy. [20; 27]

2.6 Chyby pri porovnávaní biometrických dát

Proces biometrického systému je založený na zachytení dát, spracovaní obrazu, uložení dát, porovnaní a rozhodnutí. V procese porovnávania prebieha porovnanie referenčnej šablóny z databázy s novozískanou vzorkou. Výsledkom porovnania je skóre s , čiže stupeň zhody medzi dvoma vzorkami. Hodnota prahu, je definovaná algoritmom v rozmedzí $T \in (0, 1)$. Pokiaľ je $s < T$, tak je tvrdenie o identifikácii odmietnuté, ak $s \geq T$, tak je identifikácia potvrdená. Jednotlivé výsledky môžu byť nasledujúce:

- true accept – správne prijatie,
- true reject – správne odmietnutie,
- false accept – chybné prijatie,
- false reject – chybné odmietnutie.

Na hodnotenie biometrických systémov sú významné posledné dve uvedené príklady: chybné prijatie alebo chybné odmietnutie. [20]

Miera chybného odmietnutia – False Rejection Rate (FRR)

Miera chybného prijatia alebo chyba prvého typu (Type I Error Rate), je pravdepodobnosť s akou biometrický systém neidentifikuje či neverifikuje oprávnenú osobu, napriek tomu, že už má v systéme uloženú referenčnú šablónu. FRR je možné vypočítať z pomeru celkového počtu chybných odmietnutí a počtu pokusov oprávnených osôb o identifikáciu alebo verifikáciu. Chybné odmietnutie znižuje spoľahlivosť a kvalitu identifikačných systémov. [20,28]

$$FRR = \frac{\text{počet chybné odmietnutých vzorkov}}{\text{počet pokusov oprávnených osôb}} [\%] \quad (1)$$

Miera chybného prijatia - False Acceptance Rate (FAR)


Miera chybného prijatia je pravdepodobnosť, že biometrický systém nesprávne klasifikuje dva rôzne vzory ako zhodné. Často je označovaná aj pojmom chyba druhého typu (Type II Error Rate). Teoretický výpočet je podielom celkového počtu chybného prijatia a celkového počtu porovnaní rôznych vzoriek. Miera chybného prijatia má významný vplyv na bezpečnosť biometrického systému.

$$FAR = \frac{\text{počet chybné prijatých vzorkov}}{\text{počet pokusov neoprávnených osôb}} [\%] \quad (2)$$

Hodnoty koeficientov chybného prijatia a chybného odmietnutia sa uvádzajú v relatívnych číslach v percentách. [20,28]

Miera vyrovnaných chýb – Equal Error Rate (EER)

Miera vyrovnaných chýb vyjadruje vyrovnanosť miery chybného odmietnutia a chybného prijatia. Citlivosť biometrického systému sa odráža v hodnotách FAR a FRR. Keď je prah citlivosti príliš malý znižuje sa hodnota FRR ale zároveň sa zväčšuje hodnota FAR a naopak. Čím nižšia je hodnota EER tým je systém presnejší, ideálne má byť hodnota EER je rovná 0. Pokiaľ je miera varovaných chýb v priesečníku systém má vyrovnané FRR a FAR, čo môžeme vidieť na obrázku 9. Systém používaný na identifikáciu identity má určenú mieru chybného prijatia vyššiu než mieru chybného odmietnutia, naopak to platí pre systém používaný na verifikáciu. [20, 27]



Obrázok 9: Vzťah medzi FAR, FRR a EER [zdroj:27; str.141]

Miera neschopnosti snímať – Failure To Acquire (FTA)

Miera neschopnosti snímať je definovaná ako podiel chybných vzoriek k celkovému počtu snímkov. Táto miera sa používa na hodnotenie kvality snímacích senzorov, čím je FTA vyššia, tým je senzor menej vhodný pre daný účel. [28]

$$FTA = \frac{\text{počet chybných pokusov snímání}}{\text{počet všetkých pokusov snímání}} [\%] \quad (3)$$

Miera neschopnosti registrovať – Failure To Enroll (FTE)

Miera neschopnosti registrovať je podiel vzorkov, ktoré systém nedokáže registrovať k celkovému počtu pokusov. FTE používame na hodnotenie schopnosti algoritmu pracovať s nekvalitnými charakteristikami. [20,28]

$$FTE = \frac{\text{počet chybných pokusov registrovania}}{\text{počet všetkých pokusov registrovania}} [\%] \quad (4)$$

Miera neschopnosti porovnať – Failure To Match (FTM)

Miera neschopnosti porovnať udáva percentuálny podiel biometrických vzoriek, ktoré nebolo možné porovnať so šablónou, či inak spracovať po registrácii. [28]

$$FTM = \frac{\text{počet odmietnutí po prihlásení}}{\text{počet všetkých pokusov}} [\%] \quad (5)$$

3 Rešerš metód biometrickej identifikácie s potenciálom využitia v klinických podmienkach

3.1 Príprava rešerše

Formulácia témy:

CZ: Metody biometrické identifikace s potenciálem využití v klinických podmínkách

ENG: Methods of Biometrical Identification with potential of use in clinic conditions

Kľúčové slová: biometric in oncology; biometric identification in medicine; clinic biometrics system; biometric identification based on image processing; biometrics in radiotherapy; biometrics in chemotherapy;

Časové rozmedzie: 2005-2020

Jazykové vymedzenie: Angličtina

Typy dokumentov: príspevky v zborníku, odborné články v impaktovaných časopisoch

EIZ: IEEE Xplore, Science Direct, PubMed Health, Web of Science, Google Scholar, Research Gate

3.2 Prehľadová časť

Tabuľka 2: Prehľadná charakteristika zdrojov, z ktorých bolo čerpané.

Prehľad zdrojov podľa jednotlivých databáz						
	IEEE Xplore	Science Direct	Research Gate	PubMed Health	Web of Science	Google Scholar
Celkový počet	1289	13271	6798	479	556	59530
Vybrané záznamy k rešerši	0	2	1	1	0	1

Bibliografické záznamy vybraných výsledkov:

- [1] LARTIGAU, E. PD-0567 Biometric identification of radiotherapy patients. *Radiotherapy and Oncology* [online]. 2012, **103** [cit. 2020-10-04]. ISSN 01678140. Dostupné z: doi:10.1016/S0167-8140(12)70906-4
- [2] PALMGREN, J., & LAHTINEN, T. (2009). Fingerprint recognition to assist daily identification of radiotherapy patients. *Journal of Radiotherapy in Practice*, [online]. 8(1), 17-22. doi:10.1017/S1460396908006493
- [3] SILVERSTEIN, Evan a Michael SNYDER. Implementation of facial recognition with Microsoft Kinect v2 sensor for patient verification. *Medical Physics* [online]. 2017, 44(6), 2391-2399 [cit. 2020-10-25]. ISSN 00942405. Dostupné z: doi:10.1002/mp.12241
- [4] BASAVATIA, Amar, Jose FRET, Alex LUKAJ, Hsiang KUO, Ravindra YAPARPALVI, Wolfgang A TOME a Shalom KALNICKI. Right Care for the Right Patient Each and Every Time. *Cureus* [online], 7 [cit. 2020-10-22]. ISSN 2168-8184. Dostupné z: doi:10.7759/cureus.492
- [5] CIDON, Dan. Making IT better: how biometrics can cure healthcare. *Biometric Technology Today* [online]. 20.7.2018, 2018(7), 4 [cit. 2020-10-25]. Dostupné z: doi: [https://doi.org/10.1016/S0969-4765\(18\)30094-8](https://doi.org/10.1016/S0969-4765(18)30094-8)

Tabuľka 3: Prehľadná charakteristika zdrojov, z ktorých bolo čerpané v rešerči.

Prehľad vybraných zdrojov podľa typu dokumentu, časového, jazykového a geografického pôvodu					
	[1]	[2]	[3]	[4]	[5]
Typ výsledku	Elektronický článok	Elektronický článok	Elektronický článok	Elektronický článok	Elektronický článok
EIZ	Science Direct	Research Gate	PubMed Health	Google Scholar	Science Direct
Časová lokalizácia	2012	2009	2017	2016	2018
Pôvodný jazyk výsledku	angličtina	angličtina	angličtina	angličtina	angličtina
Geografický pôvod	Francúzsko	Fínsko	USA	USA	USA

3.3 Rešerš vybraných článkov

3.3.1 Biometrická identifikácia pacientov podstupujúcich rádioterapiu

Anglický názov: Biometric identification of radiotherapy patients

Autor: E. Lartigau

Rok publikácie: 2012

Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0167814012709064>

Obsah:

Článok popisuje vytvorený systém biometrickej identifikácie na základe odtlačkov prstov pre pacientov na oddelení akademickej radiačnej onkológie v Lille vo Francúzsku. Popisovaný systém bol vytvorený v roku 2011 a používal sa na identifikáciu onkologických pacientov pri každej terapeuticknej frakcii.

Do pilotnej štúdie boli zahrnutí pacienti, ktorí boli liečení pomocou rádioterapie vonkajším žiarením. Z experimentu boli vynechaní pacienti liečení brachyterapiou a pacienti, ktorí mali menej ako 17 rokov. Celá štúdia bola pod kontrolou národného regulačného orgánu (CNIL: commission informatique et libertés) a u všetkých pacientov bol podpísaný informatívny súhlas o podstupovaní štúdie.

Po prvotnom prijatí pacienta na oddelenie akademickej radiačnej onkológie, bol pacientovi urobený snímok tváre a zaznamenaný odtlačok prsta. V priebehu 7 mesiacov, kedy bol systém zavedený na oddelenie, súhlasilo s účasťou na podstupovaní štúdie až 94,39% liečených onkologických pacientov.

Z 18 083 dodaných frakcií radiačnej terapie pre pacientov bolo 90% (16 950) úspešne identifikovaných a iba pri 3,9% frakcií nastali problémy. Väčšina neúspešných identifikácií súvisela so zlou kvalitou odtlačkov. Zlá kvalita bola spôsobená najmä týmito 4 faktormi:

- chyba použitého biometrického systému ,
- starnutie pacientov,
- pacienti, ktorí pred radiačnou liečbou podstúpili aj chemoterapiu (vplyv taxánov),
- práca pacientov (manuálna práca).

Záver:

Testovaný biometrický systém, ktorý identifikuje onkologických pacientov pomocou odtlačku prsta sa podľa výsledkov štúdie ukázal ako veľmi spoľahlivý. Vďaka svojej jednoduchosti a úspešnosti má vysoký potenciál použitia práve na pracoviskách rádioterapie. Biometrický systém je potrebné otestovať aj globálne a taktiež by bolo potrebné do štúdie zahrnúť aj pacientov s brachyterapiou. Za nevýhodu považujem hlavne komplikácie spojené s identifikáciou pacientov, ktorý podstúpili chemoterapiu.

3.3.2 Rozpoznávanie odtlačkov prstov, ktoré pomáha pri každodennej identifikácii pacientov s rádioterapiou

Anglický názov: Fingerprint recognition to assist daily identification of radiotherapy patients

Autor: J.-E. Palmgren ; T. Lahtinen

Rok publikácie: 2009

Dostupné z:

https://www.researchgate.net/publication/231915367_Fingerprint_recognition_to_assist_daily_identification_of_radiotherapy_patients

Obsah:

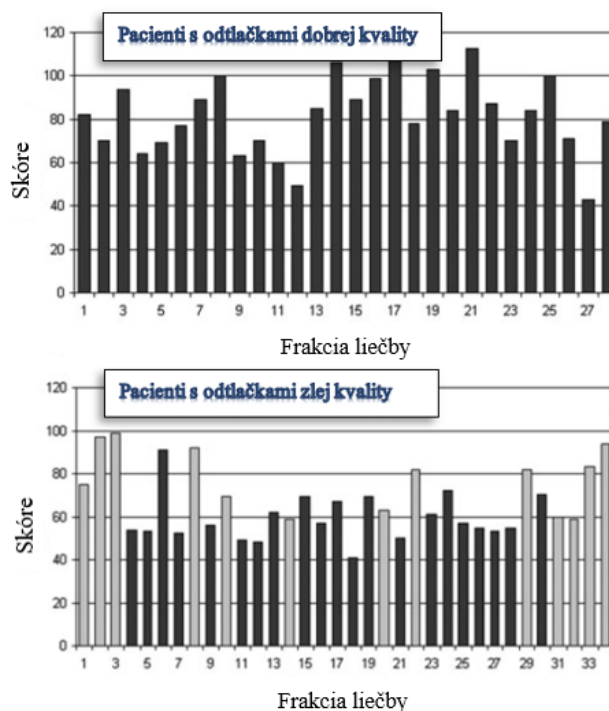
Napriek dôslednej verbálnej aj vizuálnej identifikácii pacienta v rádioterapeutických centrách sa bohužiaľ často stretávame s chybami, pri ktorých sú človeku pridelené nesprávne údaje. Výskyt týchto chýb podnecuje vysoké zaťaženie pacienta podstupujúceho liečbu, rýchle pracovné tempo personálu, pracovné zmeny, používanie skratiek a taktiež problémy so sluchom pacientov. Už pri rádioterapeutickej dávke v rádo 3-10 Gy, ktorá je dodaná zdravému alebo kritickému orgánu môže pacientovi spôsobiť zdravotné komplikácie.

V tejto štúdii sa autori rozhodli spresniť identifikácie pomocou biometrického systému. Ako najvhodnejšie sa zdali byť metódy založené na rozpoznávaní dúhovky alebo odtlačkov prstov, pretože boli komerčne dostupné a bežne sa používali v iných ako lekárskech aplikáciách. Napriek tomu, že rozpoznávanie dúhovky je presnejšie ako metóda založená na snímaní odtlačkov prstov, metóda dúhovky je náročnejšia na technickú realizáciu napr. u starších ľudí. Použitie lieky proti rakovine by tiež mohli zmeniť vaskulatúru dúhovky. Príkladom je liečba analógom prostaglandínu, ktorá spôsobuje zvýšenú pigmentáciu ľudskej dúhovky v dôsledku histologických zmien. Pri tejto štúdii bola preto zvolená metóda odtlačkov prstov.

Použitý systém obsahoval dva stolové počítače so softwarom, čítačku odtlačkov prstov a tri čítačky kontrolných bodov pre vstupy každého lineárneho urýchľovača. Čítačka odtlačkov prstov je založená na optickom princípe a dá sa pripojiť k USB portom k PC. Ihneď po nasnímaní odtlačku prsta, čítačka vypočítava číselný ekvivalent pomocou deviatich samostatných bodov a následne ich zašifruje 128-bitovým kódom.

Referenčná šablóna sa štandardne získava z pravého ukazováka, môže byť však odobratá z ktoréhokoľvek prsta v prípade, že zvolený prst nie je možné naskenovať z dôvodu jaziev, rán či iných kožných ochorení. Radiačný technológ, ktorý odoberie referenčný odtlačok prsta, môže počas procesu hodnotiť kvalitu snímku vizuálne a numericky (na stupnici od 1-100). V tejto štúdii sa používa prahová hodnota 40, ktorá sa ukázala ako optimálna.

Prieskum vo Fakultnej nemocnici v Kuopio ukázal, že 85,7% denných frakcií bolo identifikovaných úspešne. U 5,5% frakcií pacient alebo technológovia zabudli použiť identifikátor pred vstupom do ošetrovne. V 8,8% prípadoch nebol odtlačok prsta prijatý, hoci skóre referenčného obrázka odtlačku prsta bolo viac ako 40. Tento prípad sa vyskytoval najmä u starších pacientov, ktorí majú tenšiu pokožku a taktiež u ľudí, ktorí pracujú manuálne, ako sú pekári, kuchynskí robotníci a stavbári. Presné číselné hodnoty skóre dobrých odtlačkov a odtlačkov so zlou kvalitou v závislosti na frakcii nájdeme na obrázku 10.



Obrázok 10: Závislosť skóre odtlačkov s dobrou so zlou kvalitou v závislosti na frakcii
[zdroj: rešeršný článok č.2]

Pretože systém uchováva iba číselný ekvivalent niekoľkých bodov odtlačku prsta, tieto informácie nie je možné použiť na iný účel, čím sa udržiava ochrana súkromia pacientov. Databáza vymazáva staré údaje približne raz za rok, aby sa udržiavalo nízke zaťaženie pamäte počítača a zachoval sa krátky čas pri porovnávaní.

Ak pacient priloží prst na optické okienko čítačky s odlišným uhlom a polohou ako pri referenčnej vzorke, prejaví sa to na prahovom skóre. Kvôli nutnosti častého čistenia a dezinfekcie stráca membrána dotykovej obrazovky v priebehu času svoju priesvitnosť. Na minimalizáciu by bolo potrebné zmeniť čítačku každý druhý rok.

Záver:

S prihliadnutím na nízky výskyt problémových udalostí možno systém považovať za veľmi bezpečný a ako veľmi vhodný doplnok pri identifikácii pacientov na rušnom oddelení rádioterapie. Veľmi zaujímavé bolo najmä zistenie, že pri častom čistení a dezinfekcii snímača odtlačkov prstov sa priesvitná skenovacia plocha poškodzuje. Tento vplyv značne znižuje presnosť celého zariadenia a napriek jeho nízkym zaobstarávacím nákladom sa výdavky zvyšujú kvôli nutnosti výmeny každé 2 roky.

3.3.3 Implementácia rozpoznávania tváre na overenie pacientov pomocou Microsoft Kinect v2 senzoru

Anglický názov: Implementation of facial recognition with Microsoft Kinect v2 sensor for patient verification

Autor: E. Silverstein ; M. Snyder

Rok publikácie: 2017


Dostupné z: <https://pubmed.ncbi.nlm.nih.gov/28370061/>

Obsah:

Cieľom štúdie je opísať implementáciu systému rozpoznávania tváre pomocou senzoru Microsoft Kinect v2 na identifikáciu pacienta na rádioterapeutickom oddelení. Kinect v2 je systém pozostávajúci z kamery a mikrofónu s viacerými senzormi vyvinutý spoločnosťou Microsoft pre anatomické sledovanie pohybu. Bol sprístupnený ako bezplatná vývojová platforma s bezplatnou softvérovou vývojovou súpravou (SDK). Kinect sa ukázal ako cenný nástroj v rôznych oblastiach medicíny vďaka svojej schopnosti kombinovať farebný, infračervený a hĺbkový senzor v jednotnom systéme.

Na vytvorenie systému rozpoznávania tváre bola využitá vstavaná knižnica mapovania tváre HDFaceMapping. Algoritmus extrahuje 31 východiskových bodov predstavujúcich rôzne orientačné body tváre (viď obrázok 5). Tieto body sa používajú pri vytváraní súboru referenčných údajov, ako aj pri následnom vyhodnocovaní údajov snímača v reálnom čase v algoritme párovania.

Snímanie tváre začína zachytením 16 konkrétnych snímok z Kinectu, ktoré sa vytvoria pomocou nakláňania farebnej a hĺbkovej kamery: štyri pri priamom pohľade do kamery (obr.a), štyri s hlavou otočenou o 45 ° doprava (obr.b), štyri s hlavou otočenou o 45 ° vľavo (obr.c) a štyri so sklonenou hlavou hore pod uhlom 45 ° (obr.d). Obrázok 11: Polohy a orientačné body na tvári zobrazuje konkrétne pózy k procesu zhromažďovania údajov.



Obrázok 11: Polohy a orientačné body na tvári [zdroj: rešeršný článok č.3]

Následne sa z poloha každého bodu prevedie do 3D priestoru ako $p = (x, y, z)$ a pre akékoľvek dva body sa počíta absolútna vektorová vzdialenosť. Senzor obsahuje aj detekciu človeka v snímanej oblasti kamery a izoláciu tváre a trupu od pozadia pomocou tzv. „efektu zelenej obrazovky“. Vizualizácia údajov týmto spôsobom umožnila identifikáciu priemeru, \bar{x} a mediánu, \tilde{x} z rozdielov absolútnej vzdialenosti vektorov. Porovnávací proces je založený na určovaní skóre podobnosti a následným určením zhody / nezhody.

Do rozhrania bola implementovaná funkcia rozpoznávania gest rúk, čo umožnilo bezdotykové ovládanie biometrického systému. Na spustenie rozpoznávania tváre a potvrdenia totožnosti môže používateľ jednoducho otvoriť dlaň. Zatvorená päšť sa používa na odmietnutie identity.

Na otestovanie algoritmu bola vytvorená databáza 39 tvárí, každá s odvodenými 465 vektormi z východiskových bodov. Vytvorilo sa celkom 115 konkrétnych akvizícií a 5299 individuálnych porovnávacích pokusov. Pri testovaní sa overovala citlivosť systému, vyniesli sa ROC krivky a určili sa prahové hodnoty pre určenie zhody. Optimalizácia prahovej hodnoty s využitím ROC kriviek bola vypočítaná pomocou najväčšej vertikálnej vzdialenosti od čiary rovnosti a najmenej vzdialenosti od krivky k bodu (0,1). Obidve optimalizačné kritériá určili prahové hodnoty 1,61 mm pre priemer a 1,27 mm pre medián. Optimalizačnými postupmi ROC krivky sa preukázalo, že systém vykazuje citlivosť 96,5% a špecificitu 96,7%. Okrem toho sa overoval výkon systému ako aj funkcia intenzity okolitého svetla. Osvetlenie by malo mať hodnotu nad 200luxov a malo by byť konzistentné pri všetkých akvizíciách.

Záver:

Navrhnutý systém na rozpoznávanie tváre dominuje svojou vysokou robustnosťou a špecificitou, preto je vhodný na použitie v procese overenia pacienta pred rádioterapeutickou liečbou. Ukázalo sa, že svetlo zohráva veľkú rolu v zhromažďovaní údajov, pretože na presný zber údajov je potrebné primerané a konzistentné osvetlenie. Priemer aj medián sú vynikajúcimi parametrami na rozlíšenie medzi správnym a nesprávnym porovnaním. Taktiež oceňujem výpočet prahu pomocou dvoch optimalizačných kritérií, čím je kladený dostatočný dôraz na správne určenie prahu citlivosti a tým snaha o čo najnižšie číslo falošne pozitívnych výsledkov. Možnou nevýhodou navrhnutého systému je osvetlenie okuliarov pacienta, čo môže spôsobiť, že program nesprávne určí body na tvári. Problémy môže spôsobiť šatka prípadne šál okolo krku alebo na hlave.

3.3.4 Správna starostlivosť pre správneho pacienta v akokoľvek čase

Anglický názov: Right Care for the Right Patient Each and Every Time

Autor: A. Basavatia, J. Fret, A. Lukaj a spol.

Rok publikácie: 2016

Dostupné z: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4792635/>

Obsah:

Článok popisuje implementovaný biometrický systém pre pacientov na rádiačnej onkológii, ktorý využíva skenovanie krvného riečišťa dlane. Výber tejto metódy bol zvolený preto, že cievna štruktúra žíl dlane je stokrát jedinečnejšia ako odtlačok prsta a oveľa menej náročnejšia na skenovanie ako skeny dúhovky či sietnice.

Identifikačný systém skenovania dlaňových žíl PVBS bol umiestnený pred radiačný liečebný prístroj v Medical Center v Bronxe, USA, kde je pravdepodobnosť nesprávnej identifikácie najväčšia. Registračný systém ROPMS (ARIA®, Varian Medical Systems, Kalifornia) bol umiestnený na recepcii. Obidva systémy PVBS aj ROPMS sú vzájomne prepojené.

Pri registrácii je potrebné vytvoriť dva skeny dlane, pričom pacient má rozťahnuté všetky prsty tak, aby sa nedotýkali jeden druhého. U pacientov, ktorí trpia artritídou môže byť zložitejšie rozťahnúť prsty tak, aby bol snímok dostatočnej kvality, preto skenovanie trvalo dlhší čas. U pacientov do 16 rokov sa krvné riečište sa síce nemení, ale mení sa veľkosť ruky, čo môže mať vplyv na konzistentné rozmiestenie ruky. Tento problém je riešený tak, že u pacienta mladšieho ako 16 rokov je vyžadovaná každoročne nová registrácia referenčnej šablóny. Celý proces registrácie zvyčajne trvá menej než minútu. Štúdia ukázala, že celkové ovládanie systému je veľmi intuitívne a jednoduché, čo potvrdzuje fakt, že sa zamestnanci na rádioterapeutickom oddelení naučili pracovať so systémom za približne 1 hodinu.

Systém bol sledovaný v priebehu jedného roka na 1434 pacientoch. Celkový počet naskenovaných snímok za rok dosiahol 15946, pričom priemerný počet úspešne identifikovaných snímok na jedného pacienta bol 11 a naopak priemerný počet neidentifikovaných snímok predstavoval 3 snímky. Celkovo bolo zaznamenaných 4405 snímok, ktorých sa nepodarilo identifikovať. Dôvodom vyššieho čísla je to, že sú v ňom započítané aj neúspešné snímky, pri ktorých sa pacient učil, ako správne položiť ruku na skener.

Záver:

Štúdia dokázala, že krvné riečište dlane je natoľko jedinečné, že má veľkú perspektívu na identifikáciu pacienta na rádiologickom oddelení. Nevýhodou je, že u množstva pacientov je potrebné skenovať dlaň opakovane, pretože systém nerozozná identifikovanú osobu, kvôli nesprávnemu položeniu ruky na skener. Problematickejšie môže byť skenovanie dlane pacientov s artritídou, ktorým správne uloženie na ruky potrvá dlhšiu dobu a taktiež u pacientov do 16 rokov, u ktorých je potrebné proces registrácie každoročne opakovať. Pacienti, ktorým boli amputované obidve ruky túto metódu identifikácie nemôžu podstúpiť.

3.3.5 Ako môže biometria uzdraviť zdravotníctvo

Anglický názov: Making IT better: how biometrics can cure healthcare


Autor: D. Cidon

Rok publikácie: 2018

Dostupné z: <https://www.sciencedirect.com/science/article/abs/pii/S0969476518300948>

Obsah:

Tento článok skúma vplyv biometrických systémov na zdravotnú starostlivosť a identifikáciu pacientov so zameraním na americký trh. Biometrické systémy majú obrovský potenciál, keďže stále viac zdravotníckych zariadení zavádza elektronické záznamy, ktoré sú vystavované vonkajším útokom a úsilie o ochranu informácií o pacientovi je naďalej najvyššou prioritou. Až 98% nemocníc v USA pretvorilo papierové záznamy pacientov na digitalizované, čo od roku 2008 predstavuje deväťnásobný nárast. V Európe čelí zdravotnícky priemysel novým výzvam v oblasti dodržiavania predpisov podľa všeobecného nariadenia o ochrane osobných údajov (GDPR), ktoré majú výrazný vplyv na to, ako zdravotnícke organizácie používajú, udržiavajú a chránia biometrické údaje. Podľa prieskumu spoločnosti Biometrics Research Group, sa obrat trhu s biometrickými riešeniami v zdravotníctve do roku 2020 vyšplhá na približne 5 miliárd dolárov. Na obrázku 12 môžeme vidieť zvyšujúci sa trh v USA s biometrickými systémami v zdravotníctve spolu s konkrétnymi biometrickými charakteristikami:



Obrázok 12: Veľkosť trhu s biometrickými systémami v USA s technológiami 2014-2025

[zdroj: <https://www.grandviewresearch.com/industry-analysis/biometrics-in-healthcare-market> + vlastná úprava]

V roku 2017 došlo v globálnom zdravotníckom priemysle k 750 kybernetickým útokom, pričom 536 z nich sa podarilo získať citlivé údaje. Biometrické systémy môžu nielen doplniť existujúcu bezpečnostnú technológiu ale majú dôležitú úlohu v boji proti chybám pri priradovaní lekárskeho záznamu. V prieskumoch neziskovej organizácie ECRI Institute bolo preverených 7613 prípadov v 181 zariadeniach, v ktorých došlo k nesprávnej identifikácii pacienta v období od januára 2013 do augusta 2015. Počet týchto skúmaných prípadov bol len zlomkom z incidentov ku ktorým vo vybraných zariadeniach došlo. Spomedzi hlásených chýb boli mnohé fatálne.

Údaje z prieskumu ECRI dokázali, že u 91% chybné identifikovaných pacientov bola chyba zistená skôr, než pacient podstúpil liečbu. Približne 13% identifikačných chýb sa vyskytlo pri registrácii, v podobe vytvorenia duplicitných elektronických záznamov alebo tak, že informácie boli zapísané

do záznamu iného pacienta. Okrem týchto problémov nemocničné systémy často nerozoznávajú menšie odchýlky v pravopise mien.

V článku vyzdvihnutá výhoda biometrického systému rozpoznávania tváre, a to že sa pacienti nemusia dotýkať identifikačného zariadenia, čo zaisťuje bezpečné a hygienické prostredie, ktoré zabezpečuje kontrolu bezinfekčnosti a sterility v nemocnici. Využitie biometrickej identifikácie tiež zvyšuje dôveryhodnosť zdravotníckeho zariadenia.

Medzi hlavné nevýhody integrácie biometrických systémov do zdravotníctva patrí zložitosť informačných systémov. Niektoré formy identifikácie ako skenery krvného riečišťa dlane či snímanie dúhovky vyžadujú špeciálny samostatný hardware, ktorý je finančne nákladný. Okrem toho môžu vyniknúť problémy spojené s „invazívnymi“ snímačmi, pretože skenery dlane či odtlačkov prstov vyžadujú, aby sa pacienti dotýkali hardvéru alebo s ním interagovali, čo vyvoláva obavy z hygieny alebo dokonca strach z fyzického poškodenia. Ukladanie fotografií, snímok a odtlačkov prstov miliónov pacientov a zdravotníckeho personálu si vyžaduje databázovú technológiu a IT infraštruktúru, ktorá je škálovateľná, flexibilná a spoľahlivá a má možnosti zálohovania.

S cieľom nájsť nízko-nákladový no pritom efektívny spôsob implementácie biometrickej technológie sa množstvo poskytovateľov zdravotnej starostlivosti obrátilo na predajcov, ktorí ponúkajú cloudové výpočty, čo nemocniciam pomáha vyhnúť sa nutnosti nákupu IT infraštruktúry. Aby si zdravotnícke zariadenia zabezpečili rýchlu návratnosť investícií, je potrebné vypracovať si implementačný plán, ktorý zahŕňa testovanie a hodnotenie účinnosti biometrického riešenia v kľúčových bodoch, kde je najdôležitejšia identifikácia pacienta.

Záver:

Autor veľmi pútavo a komplexne objasňuje problematiku zavádzania biometrických systémov do nemocníc. Prieskumy a výsledky spoločnosti ECRI jednoznačne dokazujú nevyhnutnosť správnej identifikácie pacientov, ktorá môže mať až fatálne dôsledky na život pacienta. Veľmi zaujímavé bolo posúdenie biometrických snímačov z hľadiska udržiavania hygieny v zdravotníckom zariadení. Tento fakt využijem pri porovnaní a posudzovaní výberu vhodného biometrického systému pre onkologických pacientov. Podľa stĺpcového grafu na obrázku 12 je taktiež možné posúdiť zvyšujúci sa trend začlenenia biometrických systémov v zdravotníctve, pričom dominuje využitie odtlačkov prstov. Začlenenie správnej biometrickej technológie do zdravotníckych zariadení bezpochyby zvyšuje bezpečnosť a prevádzkovú efektívnosť súčasných systémov zdravotnej starostlivosti.

3.4 Sumarizácia a záver rešerše

Dôkladné preskúmanie týchto a ďalších materiálov bolo inšpiráciou ku koncipovaniu diplomovej práce. Bolo vychádzané z uvedených rešeršných prác, ktoré popisujú implementáciu rôznych typov biometrických systémov do zdravotníckych zariadení.

Po dôslednom hľadaní vo vedeckých databázach sa podarilo nájsť len malé množstvo relevantných článkov, ktoré sa zaoberajú danou problematikou. Tento fakt svedčí o tom, že zavádzanie biometrických systémov do medicínskeho prostredia je len na počiatku. Prevažná väčšina článkov pochádzala zo Spojených Štátov Amerických, kde už väčšina nemocníc hlavne zo súkromného sektora používa alebo plánuje používať biometrický systém, hlavne na zvýšenie bezpečnosti citlivých údajov z lekárskeho záznamu pacientov.

Väčšina z nájdených vedeckých štúdií pokladajú technológiu biometrie za veľmi perspektívnu, spoľahlivú a komplexnú na riešenie problémov identifikácie pacientov a autorizácie rôznych chránených odvetví v zdravotníctve. Stále stúpajúci trend hľadania nových riešení na zvýšenie kvality poskytovanej zdravotníckej starostlivosti a zabezpečenie bezpečnosti pacientov tlačí na vyhľadávanie nových technológií, ktoré sú dostatočne spoľahlivé. S nástupom všeobecného nariadenia o ochrane osobných údajov (GDPR) sa čoraz viac európskych zariadení zaoberá integrovaním biometrickej technológie do zdravotníctva. Veľkému záujmu o biometrickú identifikáciu taktiež prispieva to, že väčšina krajín vymieňa papierové zdravotnícke záznamy za elektronické a tým rastie tendencia rozšírenia inteligentných systémov na rýchlejšiu a spoľahlivejšiu identifikáciu pacienta.

Vybrané vedecké články sa venujú rôznym typom biometrických systémov. Medzi najpoužívanéjšie biometrické charakteristiky sa radia odtlačky prstov, snímky tváre, detekcia žíl na dlani či rozpoznávanie očnej dúhovky. Každá z týchto metód disponuje výhodami aj nevýhodami a je dôležité dôkladné zváženie na aký účel bude biometrický systém využitý. Od toho sa odvíja požadovaná citlivosť a spoľahlivosť, finančné náklady a rôzne iné kritériá.

3.5 Porovnanie metód biometrickej identifikácie a výber najvhodnejšej metódy pre identifikáciu onkologických pacientov

Na základe naštudovaných vedeckých článkov, akademických prác a kníh zaoberajúcich sa vonkajšími príznakmi onkologickej liečby a biometrických systémov sa táto práca bude prakticky zaoberať implementáciou a testovaním biometrickej identifikácie na základe rozpoznávania tváre. Výber metódy bol skonsolidovaný s požiadavkami a možnosťami na oddelení Cyberknife vo Fakultnej Nemocnici v Ostrave a práve metóda rozpoznávania tváre bola posúdená ako najvhodnejšia na použitie pri identifikácii pacientov podstupujúcich liečbu pomocou kybernetického noža.

Systémy na rozpoznávanie tváre sú druhou najpoužívanejšou metódou v zdravotníctve. Z hľadiska hardwaru si táto metóda vyžaduje hlavne kameru, ktorá je rýchlo a bezproblémovo dostupná. Nepopierateľnou výhodou sú aj pomerne nízke obstarávacie náklady. Snímanie tváre človeka je veľmi pohodlná metóda a snímaného človeka väčšinou nijako neobmedzuje.


Snímanie na základe odtlačkov prstov sa môže javiť ako presnejšia a taktiež ako cenovo výhodná metóda, no patrí medzi kontaktné metódy. Keďže kvôli zníženej imunite pacientov podstupujúcich onkologickú liečbu je nutnosť dodržiavať vysoké hygienické štandardy bola táto metóda posúdená ako neprijateľná. Nevhodnosť použitia kontaktných metód taktiež podnecuje výskyt epidemiologických chorôb, ako je napríklad práve sa vyskytujúce vírusové ochorenie covid-19. Podľa vedeckého článku (podkapitola 3.3.2) spracovávaného v rešeršnej časti diplomovej práce bolo taktiež dokázané, že priesvitná plocha skeneru sa častým čistením a používaním dezinfekcie ničí a už po dvojročnom používaní je nutné snímač vymeniť, čo z finančného ani ekologického hľadiska predstavuje ďalšiu nevýhodu tejto metódy.

Metóda založená na snímaní dlane má okrem spomínanej nevýhody nutnosti kontaktného snímania aj vyššiu chybovosť oproti ostatným fyziologickým biometrickým metódam, čo zvyšuje riziko nepresnej identifikácie.


Veľkou výhodou metódy založenej na snímaní sietnice je bezpochyby jednoduché bezkontaktné snímanie, ktoré nie je pre používateľov náročné či nepríjemné. Táto metóda patrí medzi najpresnejšiu biometrickú identifikáciu, keďže ľudské oko je najmenej meniac sa časť v priebehu času. Vysoké finančné náklady, ktoré sú spojené s vysokou cenou patentu na systém sú však výrazným obmedzením.

4 Akvizícia dát na biometrickú identifikáciu onkologických pacientov

Na úvod celého procesu je potrebné vytvoriť si databázy snímok, s ktorými budeme pracovať. Súčasťou prijímania onkologického pacienta na oddelenie Cyberknife vo Fakultnej nemocnici v Ostrave je vyfotografovanie pacienta. Po podstúpení terapeutickú liečby je pacient odfotografovaný znova. Z týchto fotiek si vytvoríme databázu s referenčnými vzorkami jednotlivých pacientov. Do trénovacej databázy vložíme snímky pacientov pred podstúpením liečby a do testovacej databázy budú vložené snímky po podstúpení onkologickej liečby. Všetky snímky upravíme tak, aby mali rovnakú veľkosť 200x113 pixelov. Všetky používané fotky sú vo formáte jpg. Na úpravu veľkosti fotiek bol použitý AVS Photo Editor.




Obrázok 13: Snímky onkologických pacientov FNO z trénovacej databázy [zdroj: autorka]



Obrázok 14: Snímky onkologických pacientov FNO z testovacej databázy [zdroj: autorka]

Na overovanie správnej funkcie biometrického systému rozpoznávania tváre využijeme aj dve verejne dostupné databázy snímok AT&T a FACES94. Výhodou využitia ďalších databáz je, že systém bude otestovaný na snímkach s odlišnými podmienkami snímania, vrátane použitia rôzneho osvetlenia, pozadia, kamerového systému, rozdielneho rozlíšenia a spektra farieb. Pri výbere databáz bol kladený dôraz na rôznorodé vplyvy a odlišnosti v snímaní a výslednom odraze.

Databáza tvárí AT&T bola nasnímaná Laboratóriom Olivetti Research v Cambridgi vo Veľkej Británii (tiež známa pod názvom ORL databáza). Obsahuje 10 rozličných fotiek tváre až 40 osôb. Fotografie sú usporiadané do 40 zložiek (jedna zložka pre každý subjekt), ktoré majú názvy v tvare sX, kde X označuje číslo subjektu (od 1 do 40). V každej z týchto zložiek je desať rôznych obrázkov jedného človeka, ktoré majú názvy v tvare Y.jpg, kde Y je číslo obrázka tohto subjektu (od 1 do 10). Všetky obrázky sú nasnímané na tmavom homogénnom pozadí a subjekty vyfotené z čelného pohľadu s určitou toleranciou na bočný pohyb. Súbory sú vo formáte JPG s veľkosťou obrázka 92 x 112 pixelov a v 256 odtieňoch šedej. [29]



Obrázok 15: Vybrané snímky do testovacej databázy tvári z AT&T [zdroj: autorka]

Databáza FACES94 obsahuje celkovo 153 osôb (133 mužov a 20 žien) a celkovo 3060 snímok. Subjekty sedeli približne v rovnakej vzdialenosti od fotoaparátu a boli požiadaní, aby hovorili, pričom sa nasnímala sekvencia dvadsiatich snímok. Vzhľadom na to, že subjekty pri fotení rozprávali, snímky obsahujú mierne a prirodzené variácie výrazu tváre. Fotky tváre boli zachytené na zelenom homogénnom pozadí s malými odchýlkami v otočení tváre. Rozlíšenie snímok je 180x200 pixelov a budeme ich využívať vo formáte JPG. Narozdiel od databázy AT&T sú všetky snímky farebné. [30]




Obrázok 16: Vybrané snímky do testovacej databázy tvári z FACES94 [zdroj: autorka]

Na testovanie algoritmov založených na odlišnom matematickom princípe budeme využívať 100 fotiek z každej sady. Dokopy teda využijeme 200 fotiek. Zo sady AT&T vyberieme fotky 10 osôb. Databáza obsahuje 10 snímok každej jednej osoby, preto snímky rozdelíme tak, aby v trénovacej sade bolo 5 fotiek a v testovacej ďalších 5 rozdielných fotiek tej istej osoby. Rovnaký princíp výberu použijeme v databáze FACES94. V tejto databáze je každá osoba odfotografovaná 20-krát, preto vyberieme len 10 fotiek jednej osoby s dôrazom na to, aby sme otestovali funkčnosť algoritmu pri rôznych zmenách v snímkach. Všetky snímky, ktoré využijeme sú vo formáte jpg. V tabuľke č.4 môžeme vidieť rôznorodé vplyvy a variácie snímania v jednotlivých databázach.

Tabuľka 4: Rozličné vlastnosti a vplyvy na snímky v databázach AT&T a FACES94

Vlastnosť	AT&T	FACES94
Veľkosť [pixelov]	92 x 112	180 x 200
Farebné spektrum	odtienie sivej	farebné
Pozadie	tmavé	zelené
Pohľad	čelný s miernym bočným vychýlením	čelný s miernym pootočením
Variácia snímku	<ul style="list-style-type: none"> • rôzny čas snímania (vplyv starnutia) • zmena osvetlenia • rôzne výrazy tváre • s/bez okuliarov 	<ul style="list-style-type: none"> • výrazná zmena výrazu tváre • zmena osvetlenia • odchýlky v otočení hlavy, náklon a sklon • zmeny v pozícii tváre na snímku

Okrem týchto databáz sme si vytvorili aj vlastnú databázu, ktorá obsahuje 100 fotiek 10 rozdielnych ľudí rôzneho veku. Tieto fotky sme rozdelili do trénovacej a testovacej sady rovnakým spôsobom ako v použitých verejných databázach. Respondenti boli požiadaní o mierne pootočenie hlavy do strán, rozdielne výrazy, aby si zatvorili oči prípadne zložili okuliare ak ich nosili. Všetky fotky boli upravené na veľkosť 112x200 pixelov a sú vo formáte jpg.



Obrázok 17: Ukážka vytvorenej trénovacej databázy tvárí [zdroj: autorka]

Kvôli dostatočnému otestovaniu vyvinutých algoritmov boli použité sprostredkované snímky zamestnancov VŠB-FEI. Tieto snímky boli výhradne použité na otestovanie funkčnosti a úspešnosti algoritmov. Použité snímky boli vo veľkosti 200x200 pixelov a boli vo formáte jpg.

4.1 Autorské práva a etický kódex

Snímky z verejných databáz sú voľne dostupné. Cieľom sprostredkovania týchto databáz je vývoj nových techník, technológií a algoritmov na automatické rozpoznávanie ľudských tvárí. Použitie spĺňa podmienky uvedené v dokumente *Dohoda o používaní* stanovené inštitúciami, ktoré databázy vyvinuli a sprostredkovali.

Všetky snímky a citlivé údaje pacientov, boli sprístupnené len na účely diplomovej práce a taktiež prešli schválením etickej komisie Fakultnej Nemocnice v Ostrave. Tvorba vlastnej databázy bola vykonávaná so súhlasom jednotlivcov a pred fotografovaním bolo každému dobrovoľníkovi vysvetlené, na aké účely budú fotografie spracovávané.

Fotografie nebudú ďalej distribuované, publikované, kopírované alebo ďalej rozširované akýmkoľvek spôsobom alebo formou.

4.2 Rôznorodosť dát

Výhodou využitia rôznych databáz je, že systém bude otestovaný na snímkach s odlišnými podmienkami snímania, čím sa poskytujú možnosti na preskúmanie a riešenie špecifických problémov. Verejné databázy sú cenný zdroj dát pomocou ktorých je možné porovnať úspešnosť jednotlivých algoritmov a riešení.

Rôzne farebné odtiene vznikajú nielen rôznym množstvom pigmentu, ale aj rôznymi spôsobmi snímania (nastavenie fotoaparátu, svetelné podmienky, pozadie atď.). Existuje viacero farebných priestorov napr. RGB, HSV, YCbCr. Snímky, ktoré budeme používať na testovanie systému sú farebné, okrem databázy AT&T, ktorá obsahuje snímky v odtieňoch sivej.

Všetky snímky, ktoré budeme používať ako referenčné vzorky spĺňajú tieto klasifikačné charakteristiky:

- forma: 2D (dvojrozmerná)
- spôsob snímania: en face (čelný pohľad) z rôznych uhlov
- forma snímky: statická
- formát: jpg
- počet tvárí na snímke: jedna.

U snímok dbáme na to, aby bola tvár zosnímaná v celej veľkosti. Na účely testovania používame snímky s rôznou farbou a homogenitou a nehomogenitou pozadia. Rôznu intenzitu osvetlenia môžeme zaznamenať najmä pri snímkach z databázy FACES94. Rozdielnosť veľkosti tváre je spôsobená vzdialenosťou fotografovej osoby od kamery. Na testovanie funkcie a úspešnosti programu používame fotografie, na ktorých nie je tvár čiastočne ani úplne prekrytá šatkou, šalom ani žiadnou prikrývkou hlavy ako je šiltovka či čiapka.

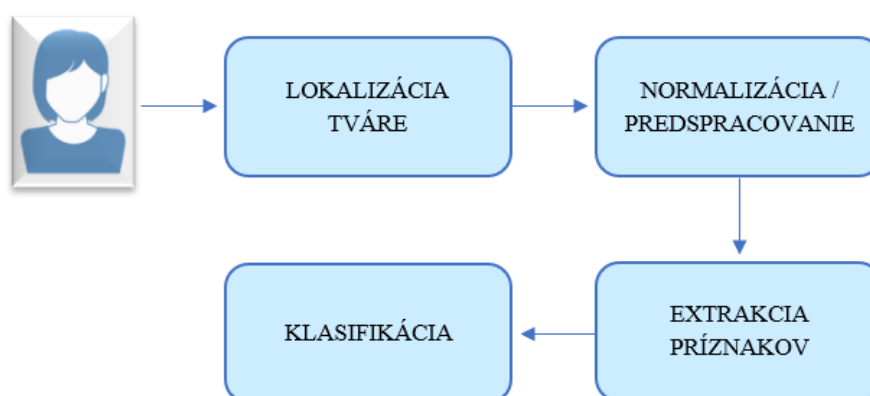
5 Implementácia a evaluácia vybraných metód biometrickej identifikácie na základe spracovania obrazu

Na úvod celkového procesu biometrického rozpoznávania tváre je potrebné nájsť oblasť, v ktorej sa tvár nachádza. Následne je potrebná normalizácia tváre, ktorej úlohou je predspracovať detekovanú oblasť a zvýšiť tým spoľahlivosť rozpoznávania. Medzi typické úlohy patrí napríklad zmena veľkosti obrázka, vyrezanie tváre z pozadia, zmena jasu – ekvalizácia histogramu a pod.

Po normalizácii dochádza k extrakcii významných charakteristických príznakov v danej oblasti. Nájsené príznaky slúžia potom k samotnej identifikácii. Extrakcia príznakov môže prebiehať pomocou rôznych metód. Pokiaľ je vstupom celá tvárová oblasť ide o holistickú metódu. Medzi holistické metódy patrí napr. analýza hlavných komponentov (PCA - Eigenfaces), lineárna diskriminačná analýza (LDA - Fisherfaces), či metóda nezávislých komponentov (ICA) . Prvé dve spomenuté metódy budú bližšie opísané, implementované a testované v nasledujúcich podkapitolách. Do ďalšej skupiny extrakčných algoritmov patria metódy založené na strojovom učení, napr. neurónové siete. V tejto diplomovej práci je jednou z troch vybraných metód aj algoritmus na základe konvolučných neurónových sietí.

Posledným krokom je klasifikácia, ktorá patrí do samotnej druhej časti, teda rozpoznávanie pomocou biometrického systému. Metódy rozpoznania tváre modelujú variabilitu rôznych tvárí tým, že analyzujú ich štatistické vlastnosti na základe veľkého množstva tréningových obrázkov. V diplomovej práci používame na klasifikáciu metódu najbližšieho suseda (1NN – Nearest Neighbor). Úspešnosť metódy na rôznych princípoch výpočtu porovnávame v podkapitole 5.5 metódy na určovanie zhody. V tejto kapitole nájdeme popis výpočtu pomocou dvoch matematických vzorcov Manhattanská (L_1) a Euklidovská (L_2) vzdialenosť. Pri algoritme využívajúcom konvolučné neurónové siete je ako klasifikátor použitá taktiež neurónová sieť.

Ako je už z predošlého testu zrejmé, na implementáciu bol využitý dvojstupňový systém rozpoznávania zložený z metódy na extrakciu príznakov a následne metódy rozpoznávania pomocou klasifikátora. Blokový diagram uvedený na obrázku nižšie popisuje proces implementácie biometrickej identifikácie.



Obrázok 18: Blokový diagram procesu biometrickej identifikácie tváre z implementačného hľadiska [zdroj: autorka]

5.1 Metódy na extrakciu príznačkov

V rámci implementácie budeme posudzovať algoritmy založené na metódach:


- analýza hlavných komponentov (PCA, známa aj pod pojmom Eigenfaces),
- (Fisherova) lineárna diskriminačná analýza (LDA),
- konvolučná neurónová sieť (CNN).

Vybrané metódy patria do takzvaných appearance-based methods, čiže metód, ktoré tvoria modely na základe dát spracovaných matematickými analýzami.

5.1.1 Analýza hlavných komponentov

Analýza hlavných komponentov (Principal Component Analysis) je metóda, ktorej cieľom je nájsť takú množinu lineárne nezávislých (nekorelovaných) koeficientov, ktoré obsahujú čo najviac informácie o vstupných dátach. PCA je vlastne analytický nástroj, ktorý umožňuje transformovať dáta z viacrozmerného priestoru do tzv. priestoru príznačkov s nižšou dimenziou (eigenfaces). Na tomto princípe je založená redundancia dát veľkých databáz snímok tváre a tým sa znižuje celkový výpočtový výkon.

V úvode sú prevedené vstupné snímky v počte n a veľkosti $M \times N$ z 2D priestoru do vektorovej podoby, čiže matica $M \times N$ sa zmení na vektor $1 \times MN$ (viď obrázok 19). V našom prípade boli vstupné snímky vo veľkostiach 200x180 pixelov (faces94 databáza) a 112x92 pixelov (AT&T databáza). Výsledný vektor pre faces94 databázu bol teda 1:36000 a výsledný vektor pre AT&T databázu bol 1:10304. Zo snímok onkologických pacientov vznikol jednotkový vektor o veľkosti 1x22600.



Obrázok 19: Prevod 2D snímku do 1D vektoru [zdroj: autorka]

Následne sa z týchto 1D vektorov zostrojí matica tak, že počet riadkov bude rovný n a počet stĺpcov bude rovný $M \times N$. Databáza obrázkov bude teda popísaná ako množina bodov vo viacdimenziálnom priestore. Vektory, ktoré najlepšie popisujú distribúciu obrázkov tváří v celom obrazovom priestore definujú podpriestor obrázkov tváre, ktorý sa nazýva *eigenspace*. Vektory, ktoré poznáme pod pojmom *eigenfaces* sú podobné ľudskej tvári a sú to vlastné vektory kovariančnej matice vypočítanej z obrazov tváří v tréningovej množine.

Samotný proces rozpoznávania začneme výpočtom priemeru z dát v matici. Nech je tréningová sada snímok tváre $x_1, x_2 \dots x_n$. Priemerné snímky tréningovej sady vypočítané podľa vzťahu (1.1) sú zobrazené na obrázku č.20.

$$m = \frac{1}{n} \sum_{i=1}^n x_i \quad (6)$$



Obrázok 20: Priemerné obrázky z trénovacej sady (zl'ava AT&T, faces94, FNO) [zdroj: autorka]

Pre centrovanie dát sa od každého obrázku z trénovacej sady odčíta priemerný obrázok. Takto vznikne vstupná matica X_m , ktorá má veľkosť $MN \times MN$ (je veľmi veľká). PCA hľadá množinu vlastných vektorov (eigenvektors) a množinu vlastných hodnôt (eigenvalues) kovariančnej matice Q , ktoré najlepšie popisujú distribúciu dát. Nájdenie kovariančnej matice prebieha pomocou vzťahu:

$$Q = \left(\frac{X_m^T \cdot X_m}{n - 1} \right) \quad (7)$$

Predpokladom pre zostrojenie kovariančnej matice je, že počet obrázkov v sade je oveľa menší ako počet bodov v jednom obrázku a teda aj v jednom vektore. V MATLABe nájdeme vlastné hodnoty (eigenvalues) a vlastné vektory (eigenvectors) a uložíme ich do premennej. Vypočítané hodnoty vektorov sa roztriedia od najväčšieho po najmenší. Následne vyberieme L počet *eigenvectors* s najväčšou hodnotou *eigenvalues*. V našom algoritme bola zvolená ako odskúšaná optimálna hodnota $L=50$. Zvolená hodnota 50, vyberie 50 dominantných vlastných vektorov, ktoré najlepšie popisujú distribúciu tváre v celom obrazovom priestore. Pokiaľ by sme zvolili nižší počet dominantných vlastných hodnôt L , rozpoznávanie tváre by nebolo dostatočné presné. Do vypočítanej bázy pre *eigenspace*, ktorý je tvorený maticou T , môže prebiehať transformácia trénovacích snímok z matice X_m do *eigenspace*. Kód PCA vytvorený v softwarovom prostredí MATLAB je prílohe A tejto diplomovej práce. [30; 31]



Obrázok 21: Ukážka eigenfaces z trénovacej sady [zdroj: autorka]

5.1.2 Lineárna diskriminačná analýza

LDA (angl. Linear discriminant analysis) známa pod názvom Fisherfaces je metóda, pri ktorej je cieľom, podobne ako pri rozpoznávaní pomocou PCA, čo najviac zredukovať priestor tváří pre hľadanie vzorov. Zatiaľ čo PCA pracuje na základe rozptylu celej množiny vstupných dát, bez ohľadu na rozdelenie dát do tried, LDA sa pokúša nájsť vektory, ktoré dokážu najzreteľnejšie odlíšiť jednotlivé triedy medzi sebou. Všetky snímky zobrazujúce tú istú osobu patria do jednej triedy. Snažíme sa minimalizovať vnútrotriedny a zároveň maximalizovať medzitriedny rozptyl dát.

V úvode postupujeme rovnako ako u PCA s tým rozdielom, že si snímky z trénovacej množiny zaradíme do tried. Z tried sa vypočíta priemerný vektor a zistí sa počet prvkov v rámci tried. Inicializujeme si maticu medzitriedneho rozptylu S_b a maticu vnútrotriedneho rozptylu S_w .

Matica rozptylu medzi triedami S_b (z anj. Between Scatter Matrix) je definovaná ako:

$$S_b = \sum_{i=1}^C N_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (8)$$

Kde N_i predstavuje počet snímkov na tréningovanie, ktoré patria do triedy i , μ_i reprezentuje priemer tréningových snímkov patriacich do triedy i a μ je priemer všetkých snímkov.

Matica rozptylu vo vnútri triedy S_w (z anj. Within Scatter Matrix) je definovaná ako:

$$S_w = \sum_{i=1}^C \sum_{x_j \in X_i} (x_j - \mu_i)(x_j - \mu_i)^T \quad (9)$$

Následne sa snažíme o maximalizáciu pomeru determinantu matice S_b a determinantu matice S_w . Matica vnútrotriedneho rozptylu S_w musí byť regulárna, čiže štvorcová matica s nenulovým determinantom a stĺpce a riadky sú lineárne nezávislé. Maximalizáciu pomeru determinantov, inak známu pod menom Fisherova úloha vypočítame ako:

$$W_{opt} = \operatorname{argmax}_W \left| \frac{W^T S_b W}{W^T S_w W} \right| = w_1, w_2 \dots w_m \quad (10)$$

$$S_b w_i = \lambda_i S_w w_i \quad i = 1, 2 \dots m \quad (11)$$

kde w_i je množina vlastných vektorov S_b a S_w . Matica W_{opt} je zložená z vlastných vektorov z trénovacej databázy pomocou PCA. Vlastné vektory sa zoradia od najväčšieho po najmenší. Projekcia dát sa prevedie do tejto množiny vektorov a po klasifikácii sa rozhoduje o najmenšej vzdialenosti ako pri metóde PCA. Podobne Ukážka algoritmu založeného na FLDA nájdeme v prílohe C. [1, str.87; 3]



Obrázok 22: Ukážka Fisherfaces z trénovacej sady [zdroj: autorka]

5.1.3 Konvolučné neurónové siete

Poslednú metódu, ktorú sme si zvolili, je metóda extrakcie príznačkov je na princípe konvolučných neurónových sietí. Spadá do kategórie umelej inteligencie, konkrétne do oblasti *Deep Learning*, v preklade učenie do hĺbky a je založená na princípe tzv. učenia s učiteľom. Algoritmus CNN je založený na konvolúcii, ktorá extrahuje z obrazových dát informácie vo forme charakteristických rysov.

Ako vstupnú množinu sme použili dáta z našich databáz. V algoritme sme použili techniku vzájomnej validácie (cross-validation), ktorá slúži na štatistickú validáciu úspešnosti pomocou dvoch nezávislých množín: trénovacej a validačnej. Množinu snímok sme si rozdelili tak, že počet trénovacích snímok bol 60%, zvyšok snímok spadalo do validačnej množiny. Validačná množina slúži na sledovanie schopnosti generalizácie alebo predikcie.

Okrem výšky a šírky obrázka bola vo vstupnej vrstve zaznamenaná aj hĺbka. Pri čiernobielych obrázkoch (AT&T databáza) bola hĺbka rovná 1, pri farebných obrázkoch bola zvolená hĺbka 3, zodpovedajúca vrstvám RGB. Vynásobením týchto troch parametrov, získame počet váh každého neurónu pri plnom prepojení. Pokiaľ by boli snímky príliš veľké, nie je možné, aby boli všetky neuróny úplne prepojené.

Aj pre výkonné počítače je veľmi časovo náročné učenie neurónovej siete, preto sme použili už čiastočne predučené siete. Tento postup sa v odbornej literatúre nazýva Transfer learning. Z dostupných predučení sietí sme si vybrali sieť z roku 2014 GoogLeNet. K prispôbeniu predučenej siete našej aplikácii sme zmenili niekoľko posledných vrstiev.

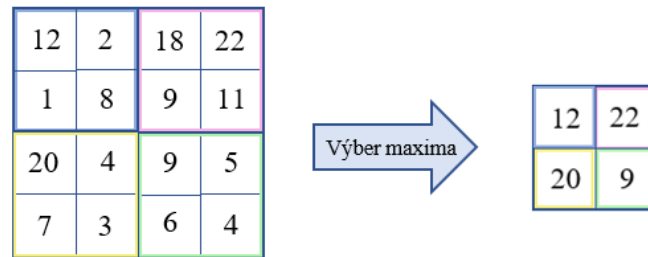
Konvolučná neurónová sieť použitá na biometrické rozpoznávanie tváre v tejto diplomovej práci sa skladá z 144 vrstiev. Medzi hlavné vrstvy patria:

- konvolučná vrstva,
- prenosová funkcia nelinearity,
- podvzorkovanie (Pooling).

Konvolučná vrstva aplikuje na vstupný snímok konvolučný filter (maska). Filter sa postupne pohybuje po celom obraze a prebieha súčin jednotlivých pixelov s hodnotami filtra. V CNN algoritme používame 22 konvolučných vrstiev s rôznymi veľkosťami filtrov. Každý filter v konvolučnej vrstve vygeneruje inú príznačkovú mapu, ktorou môžeme detekovať napr. hrany, rohy atď.

Ako **prenosová funkcia nelinearity** bola použitá aktivačná funkcia Rectified Linear Unit alebo skrátené ReLu. Táto funkcia výrazne zrýchľuje konvergenciu gradientu, nie je problém so saturáciou. ReLu funkcia vynuluje všetky hodnoty, ktoré nie sú kladné.

Pooling alebo sub-sampling redukuje priestorovú dimenziu snímku pri zachovaní jeho hĺbky. Táto redukcia dát zvyšuje výpočtový výkon siete a znižuje riziko overfittingu. V diplomovej práci je použitý typ funkcie s výberom maxima z vybraného filtra, čiže po aplikácii masky sa vyberie najvyššia hodnota. Princíp je zobrazený na obrázku č.23.




Obrázok 23: Podvzorkovanie metódou výberu najvyššej hodnoty [zdroj: autorka]

Úspešnosť siete je možné regulovať pomocou podmienok. Jednou z nich je počiatočná rýchlosť učenia, ktorá by mala byť nižšia ako rýchlosť učenia predučenej siete. Medzi ďalšie parametre patrí napr. stochastický gradient s hybnosťou, ktorý slúži na aktualizáciu váh či frekvencia overovania tréningovej siete pomocou vopred vybraných overovacích snímkov. Súčasťou algoritmu je kontrola proti premiešaniu tréningových a overovacích obrázkov a zabránenie proti preťaženiu konvolučnej neurónovej siete.

Pri strojovom učení platí pravidlo, že čím viac snímok obsahuje tréningový dataset, tým je úspešnosť rozpoznávania vyššia. V prípade, keď nemáme k dispozícii veľa tréningových dát, existuje funkcia tzv. augmentácie, čiže generovanie nových dát z dát existujúcich. Nové dáta sme vytvorili pomocou transformácií, ako napríklad náhodne preklopenie, rozťahnutie alebo zmenšenie obrázkov. V prílohách tejto diplomovej je ukážka implementácie algoritmu na základe konvolučných neurónových sietí.

Na obrázku 24 môžeme vidieť ukážku priebehu tréningového procesu konvolučnej neurónovej siete vytvorenej databázy „Moja databáza“. Horný graf znázornený modrou farbou predstavuje úspešnosť v jednotlivých iteráciách či epochách a graf v dolnej časti obrázku, ktorý je oranžovej farby predstavuje chybu tréningového procesu a má tendenciu blížiti sa k nule. [1, str.735; 2; 3; 31, 32]



Obrázok 24: Tréningový proces pomocou konvolučnej neurónovej siete [zdroj: autorka]

5.1.4 Porovnanie metód na extrakciu príznakov

Medzi hlavné výhody PCA metódy patrí jej jednoduchosť v porovnaní s ďalšími metódami na extrakciu príznakov. Pri PCA sa hodnoty intenzít využívajú priamo na učenie a rozpoznanie bez významného spracovávania. Napriek jednoduchosti sa vyznačuje pomerne vysokou úspešnosťou. Pri predspracovávaní fotiek je však nutné brať ohľad na rovnaké rozmery všetkých použitých obrázkov. Pri vysokom počte snímok v trénovacej databáze môže byť učiaci proces časovo náročnejší.

LDA delí dáta do tried, a hľadá bázu vektorov, ktoré majú najlepšiu diskrimináciu medzi triedami. Trénovací proces je časovo rýchlejší, avšak za hlavnú nevýhodu môže byť považované to, že môže dôjsť k tzv. preučeniu, teda adaptácii systému na osoby, ktoré sa zúčastnili procesu učenia. Existuje teda možnosť, že fotka novej osoby nebude od ostatných dostatočne separovaná. Výsledky úspešnosti oboch metód s použitím rôznych metrík na klasifikáciu sú zaznamenané v tabuľke č. 3 v podkapitole porovnanie metrík na určenie vzdialenosti.

Pri metóde CNN sme využili metódu Transfer learning, čo znamená, že sme použili sieť GoogLeNet, ktorá je predučená na podobný typ úloh a zmenili sme niekoľko jej vrstiev. Zvolený spôsob šetrí výpočtovú pamäť a značne urýchľuje proces učenia. V porovnaní s metódami PCA a LDA je trénovací proces rýchlejší. Oproti PCA a LDA má však nižšiu schopnosť rozpoznávať snímky s pootočením tváre. Jednou z nevýhod je aj to, že CNN potrebuje veľa trénovacích snímok oproti predchádzajúcim metódam.

5.2 Metódy na určovanie zhody

Na určovanie zhody medzi hľadanou tvárou z trénovacej databázy a rozpoznanou tvárou z testovacej databázy pri PCA a LDA metóde bola použitá zhukovacia metóda najbližšieho suseda. Metóda sa taktiež označuje aj ako 1NN klasifikácia (anj. Nearest Neighbor) a na rozdiel od predchádzajúcich metód na extrakciu príznakov sa neučí iba rozhoduje. Cieľom je určiť, ktorému obrázku z trénovacej sady zodpovedajú vypočítané hodnoty. Na rozhodnutie sa využíva zistenie vzdialenosti medzi trénovacími eigenfaces x a eigenface neznámeho obrázku y z testovacej sady. Obrázok z testovacej databázy je zhodný s obrázkom z trénovacej databázy, medzi ktorým je najmenšia vzdialenosť. Na výpočet vzdialenosti sme využili tieto dve metriky :


Manhattanská vzdialenosť (často označovaná ako L_1):

$$L_1(x, y) = |x_i - y_i| \quad (12)$$

Euklidovská vzdialenosť (často označovaná ako L_2):

$$L_2(x, y) = \sqrt{(x_i - y_i)^2} \quad (13)$$

Na obrázku č. 25 môžeme názorne vidieť dosah spomínaných metrík.



Obrázok 25: Porovnanie dosahu Euklidovskej a Manhattanskej metriky [zdroj: autorka]

5.2.1 Porovnanie metrík na určenie vzdialenosti

Použité metriky sme otestovali na algoritme založenom na PCA a klasifikačnej zhukovacej metóde NN na vybraných testovacích obrázkoch z databáz AT&T, FACES94 a na snímkach pacientov FNO. Z tabuľky č.5 vyplýva, že vyššiu úspešnosť dosiahla biometrická identifikácia tváre s Euklidovskou metrikou.

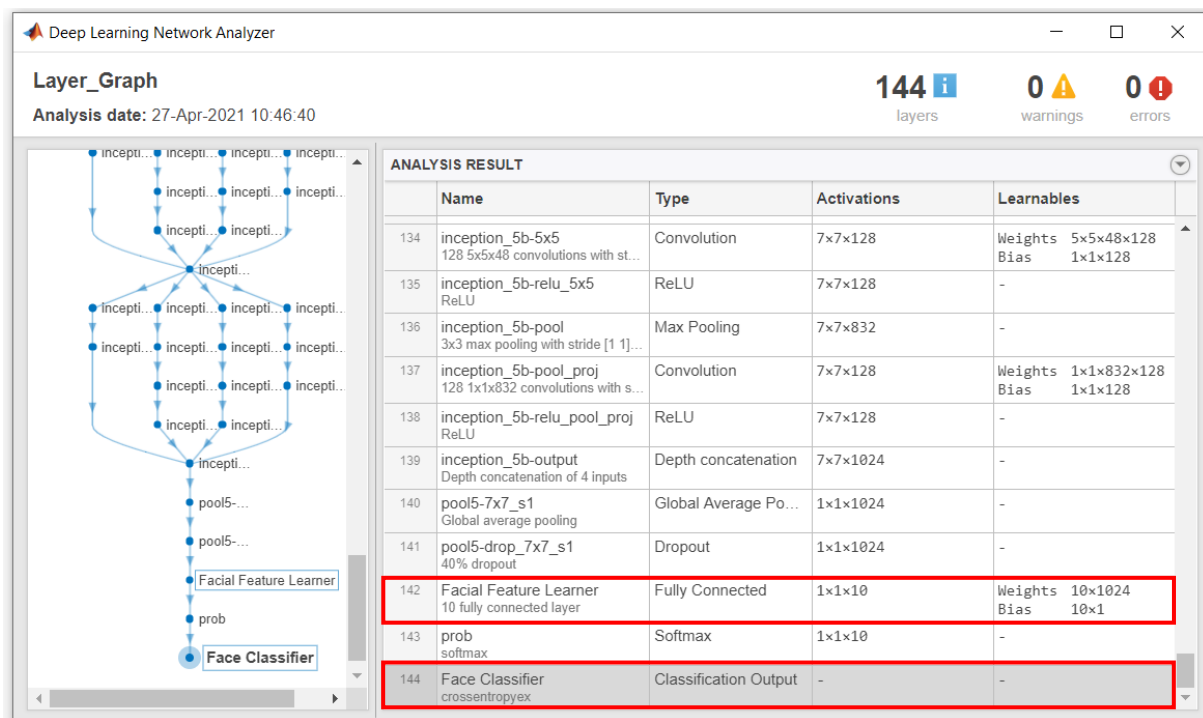
Výpočet úspešnosti prebiehal podľa vzorca:

$$U = \frac{\text{počet úspešne rozpoznaných snímokov}}{\text{počet všetkých snímokov}} * 100 \text{ [\%]} \quad (14)$$

Tabuľka 5: Úspešnosť rozpoznania rozličných metrík s využitím metódy najbližšieho suseda

	Databáza AT&T	Databáza Faces94	Pacienti FNO	Moja databáza	Zamestnanci VŠB-FEI
PCA+NN s Euklidovskou metrikou	98%	100%	67%	98%	100%
PCA+NN s Manhattanskou metrikou	96%	98%	67%	96%	100%
LDA+NN s Euklidovskou metrikou	97%	96%	67%	98%	93%
LDA+NN s Manhattanskou metrikou	94%	96%	50%	96%	86%

Na klasifikáciu pri konvolučných neurónových sieťach bola použitá klasifikácia tiež na základe neurónových sietí. Na tento účel bola zavedená plne prepojená vrstva (z anj. FCL Fully Connected Layer), ktorá je špecifická pre jednotlivé použitie. Touto vrstvou sme zaviedli ďalšiu nelinearitu do modelu. Výmenu vrstiev predčenej siete GoogLeNet sme vykonali aj vo výstupnej vrstve č. 144 (z anj. Output Layer), ktorá je zodpovedná za klasifikáciu objektov. Zmenené vrstvy môžeme vidieť na obrázku č.26. Na veľkosti dátového súboru, resp. počtu osôb, ktoré máme zaznamenaných v trénovacej databáze závisí počet tried klasifikátora. Počet tried následne určí, koľko bude mať neurónová sieť úplne prepojených vrstiev. Následne je vykonaná klasifikácia na základe konvolučných neurónových sietí vybranej snímky z testovacej databázy.



Obrázok 26: Ukážka zmenených klasifikačných vrstiev z predloženej siete GoogLeNet [zdroj: autorka]

6 Testovanie vybraných metód na biometrickú identifikáciu tváre

6.1 Vplyv odlišných vlastností fotiek na úspešnosť rozpoznávania

Testovacie meranie sme vykonali na 50 tréningových a rozdielnych 50 testovacích snímkach z oboch verejných databáz (dokopy 200 snímkov), zo všetkých 12 snímok šiestich pacientov, ktoré nám boli poskytnuté oddelením CyberKnife vo Fakultnej nemocnici v Ostrave a taktiež na všetkých snímkach vytvorenej databázy. V tréningovej databáze AT&T, faces94 a Moja databáza bolo uložených 5 rozličných snímkov každej osoby. Snímky v tréningovej a testovacej databáze neboli zhodné. Pri výbere snímkov do testovacej databázy bol kladený dôraz na zahrnutie rôznych vedľajších vplyvov tak, aby boli algoritmy rozpoznávania tváre dostatočne otestované. Tréningová databáza pacientov z FNO obsahovala snímky pacientov pred podstúpením liečby a v testovacej databáze boli snímky po podstúpení onkologickej liečby.

V rámci overovania správnej funkcie programu sme do procesu rozpoznávania tváre zahrňali snímky, ktoré boli snímané v rôznych svetelných podmienkach, či s odlišným výrazom tváre. Úspešnosť rozpoznania sme porovnávali aj na subjektoch, ktorý mali zatvorené oči, alebo ich pohľad smeroval do strán. Na obrázku č.27 môžeme vidieť vybranú testovaciu snímku z verejnej databázy ATT, na ktorej má osoba odlišný výraz tváre ako na snímku, ktorý máme uložený v tréningovej databáze. Algoritmus napriek tejto zmene úspešne zaznamenal. Ani výrazná zmena výrazu tváre či zatvorenie očí nemali vplyv na úspešnosť systému.



Obrázok 27: Vplyv výrazu tváre a zatvorených očí na rozpoznanie tváre (snímka z databázy ATT)
[zdroj: autorka]

Zo snímkov onkologických pacientov sme testovali úspešnosť biometrického systému na orezanom snímku. Fotka pacientky s orezaním tváre bola uložená do tréningovej sady snímkov a vzdialená fotka rovnakej pacientky po liečbe bola uložená do testovacej sady. Vplyv orezania tváre sme testovali aj na orezaných snímkach z ďalších databáz a aj tieto snímky dokázal algoritmus správne rozpoznať.



Obrázok 28: Vplyv orezania na rozpoznanie tváre (snímka z databázy pacientov FNO) [zdroj: autorka]

Úspešnosť rozpoznania bola porovnávaná aj na rozmazaných snímkach tváre. S rozmazanými snímkami z verejných databáz FACES94 a AT&T prebehlo rozpoznanie bez problémov, avšak pri rozmazanej snímke pacienta z onkologického oddelenia FNO, algoritmus nedokázal správne určiť zhodnú snímku pacienta z trénovacej databázy.



Obrázok 29: Vplyv rozlíšenia a výrazu na rozpoznanie tváre (snímka z databázy faces94) [zdroj: autorka]

Testovanie prebiehalo aj na snímkach, na ktorých mali subjekty pootočenú tvár do strán. Systém odkázal úspešne rozpoznať hľadanú tvár do uhlu 50°. Pri vyššom uhle už nebola viditeľná druhá polovica tváre a porovnávanie bolo neúspešné. Na obrázku č.30 , môžeme vidieť úspešné rozpoznanie pootočenej tváre.



Obrázok 30: Vplyv pootočenia tváre na rozpoznanie tváre (snímka z databázy Moja databáza) [zdroj: autorka]

Do porovnávania boli taktiež zahrnuté snímky s rozličnými svetelnými podmienkami. Vzhľadom na to, že sme použili snímky z databáz AT&T a faces94, ako aj vytvorené snímky a snímky z pacientov z onkologického oddelenia, program bol otestovaný na snímkach s rôznou veľkosťou aj farebnou škálou, odlišným pozadím a taktiež boli snímané rozdielnym kamerovým systémom.

6.2 Vplyv zmeny vzhľadu tváre na úspešnosť rozpoznávania

Na snímke onkologického pacienta, ktorý podstúpil liečbu na oddelení CyberKnife vo Fakultnej nemocnici v Ostrave sme mali možnosť zhodnotiť funkčnosť algoritmu na snímke s fúzami a bez fúzov a taktiež s odlišným štýlom účesu. Na fotke môžeme zaznamenať aj výraznejšiu zmenu vzhľadu pacienta vplyvom času a podstúpenia liečby. Všetky hodnotené metódy nemali problém s rozpoznávaním takejto snímky tváre.



Obrázok 31: Vplyv fúzov a účesu na rozpoznávanie tváre (snímka z databázy pacientov FNO)
[zdroj: autorka]

Do testovania boli zahrnuté aj vplyvy starnutia. Systém nemal problém rozpoznať sériu snímok ľudí, ktorý boli fotený po určitom časovom období. Na posúdenie tohto vplyvu boli použité hlavne snímky z databázy ATT a snímky pacientov po podstúpení liečby. Rozpoznávaciemu algoritmu sa podarilo rozpoznať aj subjekty, ktorých fotka v tréningovej databáze bola bez okuliarov a v testovacej databáze bola snímka subjektu nasnímaná s okuliarmi. Na obrázku nižšie vidíme snímku z databázy vytvorenej na účely diplomovej práce.




Obrázok 32: Vplyv okuliarov na rozpoznávanie tváre (snímka z vytvorenej databázy Moja databáza)
[zdroj: autorka]

Z databázy ATT sme mali možnosť otestovať kombináciu okuliarov a starnutia. Výsledky dopadli úspešne. Otestovaná bola taktiež kombinácia rôznych vplyvov. Ako problémová sa ukázala byť kombinácia rozmazanej snímky a nehomogénneho pozadia. Výsledky testov sú zahrnuté do požiadaviek na správne snímanie osoby.

6.3 Vplyv množstva tréovacích fotiek na úspešnosť rozpoznávania

Súčasťou testovania vytvoreného biometrického systému bolo aj zisťovanie závislosti medzi množstvom fotiek v tréningovej databáze a úspešnosťou systému. V literatúre sa stretneme s popisom problému jednej dostupnej vzorky (angl. one sample per subject problem), čiže s problematickým tréningom biometrického algoritmu len s jednou dostupnou vzorkou. Je zrejmé, že čím viac informácií o subjekte máme, tým bude rozpoznávanie presnejšie.

Vplyv množstva tréovacích fotiek sme posudzovali na desiatich respondentoch z vytvorenej databázy Moja databáza, z ktorej sme postupne použili na tréningovanie 1-7 fotiek jednej osoby. V grafe na obrázku č. 31 môžeme vidieť, že úspešnosť systému pri jednej fotke dosahovala 88% a pri piatich fotkách sa úspešnosť zvýšila o 10%. Po použití viacerých fotiek sa už úspešnosť zvyšovala minimálne. Vzhľadom na rýchlosť tréningového procesu a taktiež kvôli zníženiu zaťaženia pamäte sme posúdili za vhodné vložiť do databázy 5 fotiek pri vkladaní nového pacienta pred podstúpením liečby do databázy slúžiacej na biometrické rozpoznanie. V grafe na obrázku 33 môžeme vidieť úspešnosť vplyvu množstva fotiek. Pri hodnotení bol použitý extrakčný algoritmus PCA a na klasifikáciu bola použitá metóda NN založená na výpočte Euklidovskej vzdialenosti.



Obrázok 33: Závislosť počtu fotiek jednej osoby na úspešnosti rozpoznávania [zdroj: autorka]

7 Vyhodnotenie a selekcia metódy na biometrickú identifikáciu na základe efektivity a robustnosti

Z výsledkov posudzovania úspešnosti algoritmov na extrakciu príznačkov a klasifikáciu a taktiež celkového testovacieho procesu sme získali nasledujúce výsledky:

V kapitole 1.3 sme porovnávali tri vybrané metódy na extrakciu príznačkov: Analýza hlavných komponentov, Lineárna diskriminačná analýza a Konvolučné neurónové siete. Analýza hlavných komponentov (PCA) vykazovala najvyššiu úspešnosť. Naopak podľa dosiahnutých výsledkov sme zaznamenali najnižšiu úspešnosť založenej na Fischerovej lineárnej diskriminačnej analýze (FLDA). Pri PCA sa hodnoty intenzít využívajú priamo na učenie a rozpoznanie bez významného spracovávania. Napriek jednoduchosti dosahuje vysokú úspešnosť (viď tabuľka 6). Pri predspracovávaní fotiek je však nutné dodržiavať rovnaké rozmery všetkých použitých obrázkov. Pri vysokom počte snímok v tréningovej databáze môže byť učiaci proces časovo náročnejší.

Pri metóde CNN sme využili metódu Transfer learning, čo znamená, že sme použili sieť GoogLeNet, ktorá je predurčená na podobný typ úloh a zmenili sme niekoľko jej vrstiev. Zvolený spôsob šetrí výpočtovú pamäť a značne urýchľuje proces učenia. V porovnaní s metódami PCA a LDA je tréningový proces rýchlejší. Oproti PCA a LDA má však nižšiu schopnosť rozpoznávať snímky s pootočením tváre. Jednou z nevýhod je aj to, že CNN potrebuje veľa tréningových snímok oproti predchádzajúcim metódam.

Medzi hodnotené klasifikačné metódy sme zaradili algoritmy na princípe hľadania najbližšieho suseda. Pri extrakčných metódach PCA a FLDA sme porovnávali úspešnosť klasifikácie na výpočte minimálnej vzdialenosti pomocou Euklidovskej a Manhhattanskej vzdialenosti, pričom sme pri oboch metódach vyhodnotili ako vhodnejšiu Euklidovskú vzdialenosť. Výsledky a zhodnotenie úspešnosti pri použití 2 rozličných výpočtov vzdialenosti nájdeme v podkapitole 5.2.1. Pri metóde na základe konvolučnej neurónovej siete (CNN) bola ako klasifikačná metóda použitá taktiež neurónová sieť. V tabuľke č.6 sú uvedené úspešnosti jednotlivých extrakčných metód, ktoré na výpočet minimálnej vzdialenosti využívajú princíp Euklidovskej vzdialenosti.

Tabuľka 6: Porovnanie úspešnosti jednotlivých metód použitých v tréningovom procese


	Databáza AT&T	Databáza Faces94	Pacienti FNO	Moja databáza	Zamestnanci VŠB-FEI
PCA	98%	100%	67%	98%	100%
LDA	97%	96%	67%	98%	93%
CNN	75%	100%	67%	97%	96%

Do testovacieho procesu sme zahrnuli aj hodnotenie rozličných vonkajších vplyvov a zmeny vzhľadu tváre testovanej osoby. Úspešnosť systému neovplyvnila zmena výrazu tváre, orezanie snímky či to, že mal subjekt zložené okuliare. Ako problémová sa ukázala byť kombinácia rozmazanej snímky a nehomogénneho pozadia a taktiež v niektorých prípadoch mal systém problém s výrazným pootočeným tváre nad 45 stupňov. Výsledky testov sú zahrnuté do požiadaviek na správne snímanie osoby.

V neposlednom rade sme hodnotili vplyv množstva fotiek na úspešnosť rozpoznávania. Optimálny počet bol stanovený na 5 fotiek jednej osoby, ktorú vkladáme do databázy na biometrické rozpoznanie tváre. Pri vkladaní viacerých fotiek sa úspešnosť systému zvyšovala minimálne, takže vzhľadom na šetrenie výpočtovej pamäte a taktiež kvôli zníženiu času trénovacieho procesu sme usúdili za najvhodnejšie vkladať do databázy 5 fotiek jednej osoby.

8 Tvorba používateľského rozhrania vybranej biometrickej metódy

Súčasťou diplomovej práce je aj implementácia algoritmu biometrickej identifikácie do užívateľsky prijateľného prostredia pomocou MATLAB aplikácie. Vybraná extrakčná metóda PCA ktorá sa v testovacom meraní ukázala ako najvhodnejšia bola spracovaná pomocou software MATLAB 2020a. Aplikácia bola taktiež doplnená o možnosť zvoliť si aj metódu CNN, ktorej trénovací proces trvá podstatne kratšie. Na klasifikáciu bola použitá ako hlavná klastrovacia metóda NN (z anj. Nearest Neighbor), ktorá na výpočet minimálnej vzdialenosti používa Euklidovskú vzdialenosť. Celkový biometrický systém je zložený z niekoľkých častí ktoré môžeme vidieť na nasledujúcom blokovom diagrame:



Obrázok 34: Blokový diagram jednotlivých častí biometrického systému [zdroj: autorka]

Vytvorená aplikácia obsahuje 3 okná:

- nasnímanie snímok: slúži na snímanie snímok do trénovacej alebo testovacej databázy,
- aktualizácia databázy: slúži na opätovné natrénovanie systému pri pridaní snímok novej osoby do databázy,
- rozpoznávanie snímok: slúži na rozpoznávanie tváre.

Jednotlivé fázy procesu biometrickej identifikácie a taktiež obsah a funkcia okien v aplikácii sú popísané v nasledujúcich kapitolách.

8.1 Nasnímanie tváre

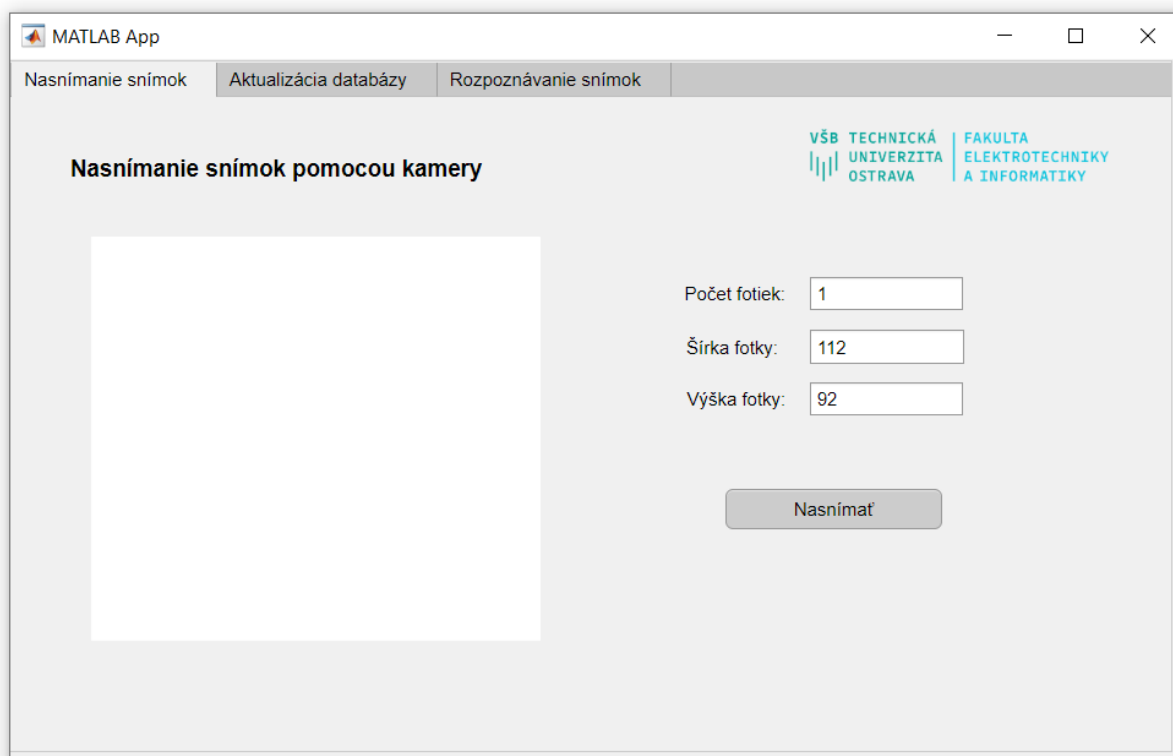
V úvode celého procesu je potrebné predspracovanie databázových trénovacích snímok ale aj snímok, ktoré chceme rozpoznávať pomocou navrhnutého biometrického systému. Predspracovanie zahŕňa úkony ako úprava veľkosti dokumentu, premena do šedej škály a úprava kontrastu a iné. Pri snímaní snímok, ktoré budeme detekovať ako aj pri snímkach v databáze je potrebné, aby bola tvár pacienta zreteľne zaznamenaná na homogénnom pozadí. Najvhodnejšie je zosnímať tvár subjektu z rôznych uhlov a pri odlišných výrazoch tváre. Platí pravidlo, že čím viac informácií o subjekte máme, tým bude proces rozpoznávania presnejší. V testovaní vplyvu množstva fotiek v podkapitole 1.7 tejto diplomovej práce sa ukázalo najvhodnejšie uložiť do databázy minimálne 5 snímok snímaného subjektu. Na snímke je potrebné zaznamenať celú tvár. Pri zmene veľkosti snímky tváre je potrebné zachovať tzv. ROI (z anj. regions of interest), teda našu oblasť záujmu, čo je celá pacientova tvár. Základné podmienky snímania vyplývajúce z testovacej časti diplomovej práce sme stručne zhrnuli do niekoľkých bodov podmienok snímania.

Podmienky snímania:

- všetky snímky uložené v databáze musia mať rovnakú veľkosť $M \times N$ v pixeloch, pričom M je výška a N je šírka snímky,
- do databázy vkladáme 5 snímok jednej osoby,
- v snímkach dbáme na to aby bol subjekt snímaný na homogénnom pozadí,
- na snímke musí byť zaznamenaná celá tvár subjektu.

Na uľahčenie zachovania rovnakých rozmerov a množstva fotiek v databáze je súčasťou aplikácie karta, ktoré sníma subjekt pomocou kamery. Aplikácia je prednastavená na snímkanie pomocou počítačovej webkamery ale pri menšej úprave kódu existuje možnosť pozmeniť zdrojovú kameru podľa konkrétnych možností a použitia.

V okne *Nasnímanie snímok* si môže používateľ zvoliť koľko snímok chce nasnímať a taktiež rozmery. Snímky sa automaticky uložia do zložky, pričom je potrebné aby ich užívateľ správne premenoval a zaradil do priečinku Trénovacia alebo Testovacia databáza, podľa účelu, na ktorý bude snímok použitý. Po kliknutí tlačidla *Nasnímať* sa v bielej časti okna zobrazí pohľad kamery a po indikácii ľudskej tváre automaticky prebehne zosnímanie subjektu. Ukážku okna *Nasnímanie snímok* môžeme vidieť na obrázku č.35. Výhodou algoritmu v karte *Nasnímanie tváre* je, že tvár nebude zosnímaná pokiaľ má človek akokoľvek prekrytú tvár, keďže disponuje lokalizáciou ROI (region of interests), čo je v našom prípade ľudská tvár.



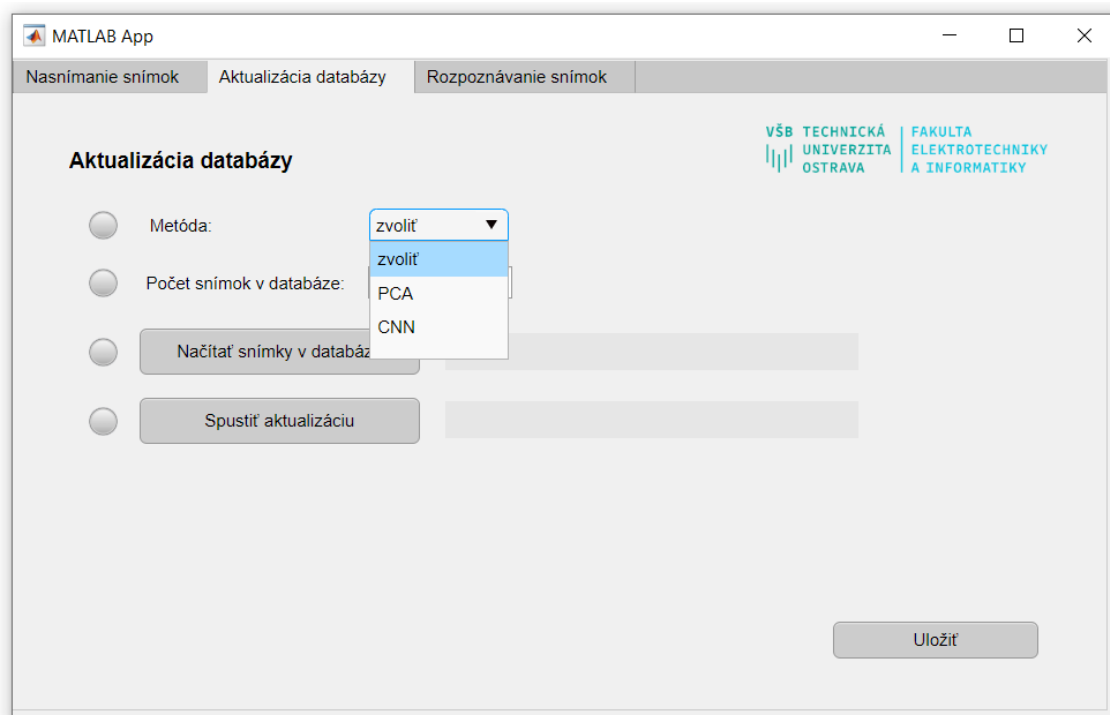
Obrázok 35: Ukážka okna „Nasnímanie snímok“ v aplikácii MATLAB [zdroj: autorka]

V ďalšom spracovávaní prebehne automaticky premena farebného snímku na odtiene šedej pomocou funkcie `rgb2gray` a úprava kontrastu pomocou funkcie `stretchlim`.

8.2 Aktualizácia databázy a trénovací proces

Po tom ako máme pripravené snímky v databáze je potrebné spustiť trénovací proces. Aplikácia umožňuje zvoliť metódu medzi PCA a CNN. Ako najúspešnejšia metóda z testovania popísaného v predošlých kapitolách bola zvolená analýza hlavných komponentov, ktorej princíp je popísaný v podkapitole 1.3.1. Všetky obrázky z databázy sú najskôr prevedené do vektora o veľkosti $1 \times M \times N$, pričom M predstavuje výšku a N šírku trénovaných snímkov. Následne sa vypočíta pomocou Matlab funkcie *mean* priemer každej snímky a vytvorí sa kovariančná matica. Na redukcii dát sa vyberie 50 dominantných vlastných hodnôt, ktoré extrahujeme z kovariančnej matice. Dominantné eigenvalues alebo teda dominantné vlastné hodnoty najlepšie popisujú distribúciu tváre v celom obrazovom priestore. Ukončením trénovacieho procesu je prepočítanie všetkých snímok v databáze do PCA priestoru (eigenspace). Vzhľadom na to, že trénovací proces metódy PCA je časovo náročnejší je tu možnosť zvoliť si metódu CNN. Princíp tejto metódy je popísaný v podkapitole 5.4.3. Vzhľadom na to, že metóda LDA nedosahovala dobré výsledky úspešnosti a trénovací proces bol zdĺhavý, do aplikácie nebola zaradená.

Na spustenie trénovacieho procesu slúži karta *Aktualizácia databázy*. Na úvod si používateľ zvolí *Metódu*, pomocou ktorej bude celý algoritmus (extrakčný aj klasifikačný) pracovať. Taktiež obsahuje editovateľné okno počet snímok v databáze a následne tlačidlá *Načítať snímky v databáze* a *Spustiť aktualizáciu*. Celkový trénovací proces môže trvať aj niekoľko minút, záleží na počte a veľkosti fotiek v databáze. Preto je vhodné uložiť si vypočítané dáta pomocou tlačidla *Uložiť*, ktoré sa nachádza v pravom dolnom rohu. Pokiaľ do databázy nepridávame fotky novej osoby a premenné z workspace trénovacieho procesu máme uložené formou súboru je možné tento krok preskočiť. Na obrázku č. 36 môžeme vidieť prostredie aplikácie v karte *Aktualizácia databázy* s rozprestretou voľbou metódy.



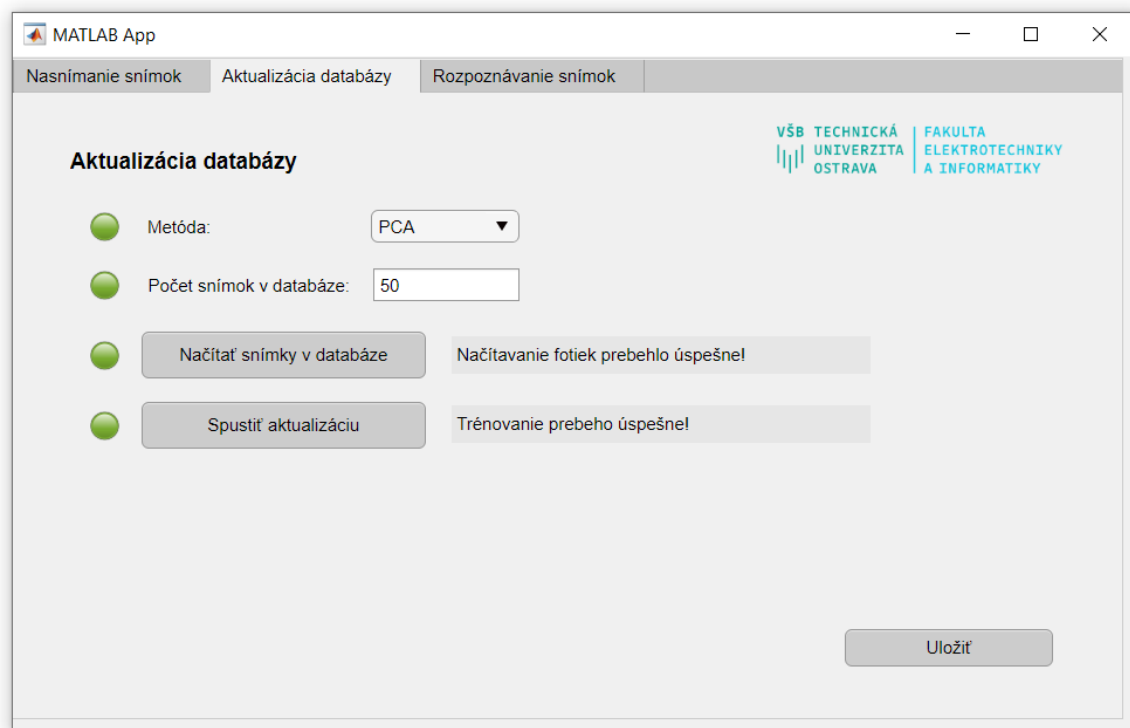
Obrázok 36: Ukážka karty „Aktualizácia databázy“ v aplikácii MATLAB (voľba metódy)
[zdroj: autorka]

Po výbere metódy si používateľ zvolí počet fotiek, ktoré sa nachádzajú v zložke spolu so súborom aplikácie. Tieto fotky predstavujú trénovaciu množinu, podľa ktorých bude aplikácia v ďalšom kroku rozpoznávania posudzovať zhodu s hľadanou fotkou. Je potrebné aby používateľ uviedol správny počet fotiek, ktoré ľahko zistí, keď sa presunie do zdrojového priečinka Trénovacia databáza. Súbor v zložke sú pomenované poradovým číslom. Do editovateľného poľa *počet snímok v databáze* nie je možné pridávať záporné čísla. Aplikácia neumožní používateľovi pridať číslo ktoré nepatrí do množiny prirodzených čísel. Pokiaľ je pridaný správny počet trénovacích obrázkov rozsvieti sa zelená kontrolka.

Následne používateľ klikne na tlačidlo Načítať snímky v databáze. Tento proces je zvyčajne rýchly a do pár sekúnd prebehne načítanie všetkých fotiek, ktoré sa nachádzajú v rovnakom priečinku ako zdrojový súbor aplikácie. Následne sa rozsvieti indikačná kontrolka, nachádzajúca sa naľavo od tlačidla a zobrazí sa informatívny nápis, že načítavanie fotiek prebehlo úspešne.

Posledným a časovo najnáročnejším krokom aktualizácie databázy je spustenie trénovacieho procesu pomocou tlačidla *Spustiť aktualizáciu*. V tomto kroku prebiehajú vyššie spomínané výpočty z kovariančnej matice, získavanie vlastných hodnôt a vlastných vektorov. Po úspešnej aktualizácii sa zmení posledná šedá kontrolka na zelenú farbu a napravo od tlačidla sa zobrazí text: *Trénovanie prebehlo úspešne*. Týmto krokom sa ukončuje aktualizácia databázy a používateľovi zostáva už len uložiť vypočítané výsledky.

Po kliknutí tlačidla uložiť sa vypočítané premenné automaticky premietnu do workspace Matlabu a následne sa uložia do priečinka trénovacej množiny k súboru aplikácie. Uloženie významne zrýchli celkový proces rozpoznávania. Pokiaľ používateľ nepridáva nové snímky do databázy tak mu uloženie vypočítaných premenných z aktualizácie databázy umožní preskočiť opätovnú aktualizáciu databázy po každom spustení aplikácie. Na obrázku č. 37 môžeme vidieť ukážku karty *Aktualizácia databázy* po ukončení trénovacieho procesu.



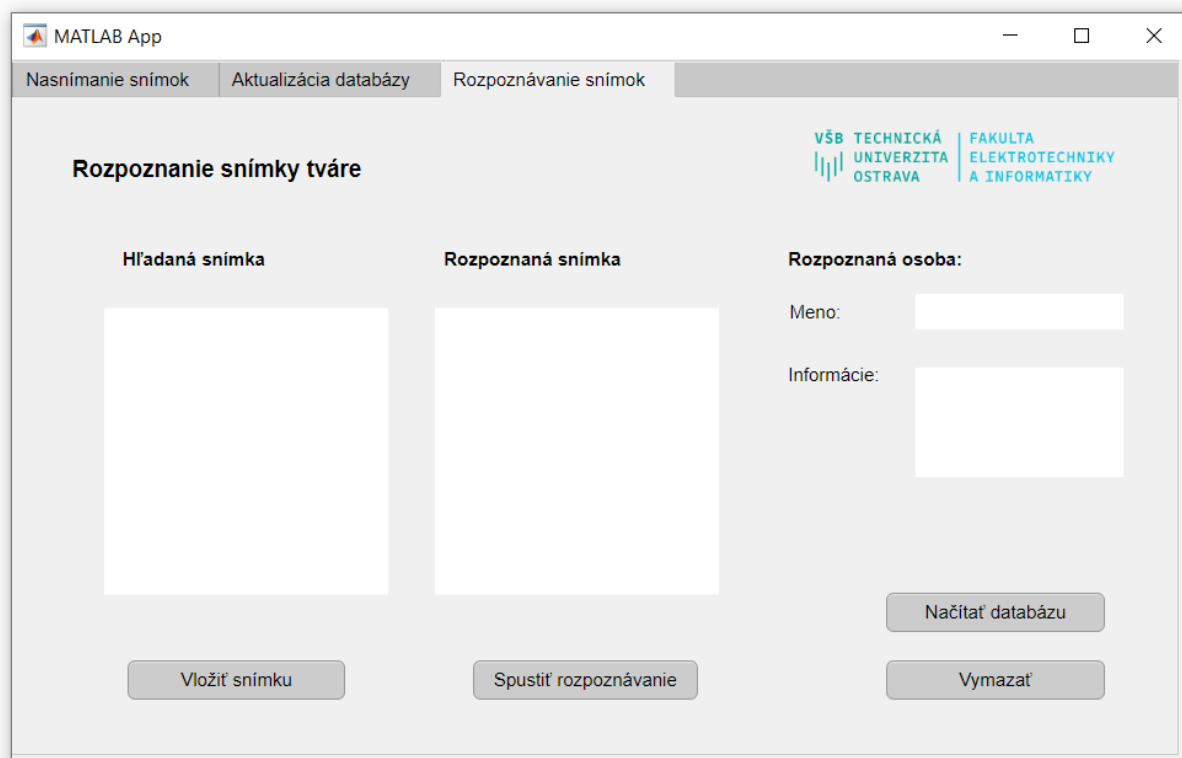
Obrázok 37: Karta „Aktualizácia databázy“ po ukončení trénovacieho procesu v aplikácii MATLAB
[zdroj: autorka]

8.3 Predikcia identity a rozpoznávanie snímkov

Posledným a jedným z najdôležitejších krokov je samotné rozpoznávanie nasnímanej tváre. Tento proces je založený na klasifikačnom algoritme najbližšieho suseda (NN Nearest Neighbor). NN je algoritmus strojového učenia, ktorý rozdelí prvky z trénovacej množiny do zhlukov. Následne prebehne klasifikácia, v ktorej je prvok umiestnený do podpriestoru podľa vlastností. Ako už z názvu môžeme predpokladať, v podpriestore je potrebné nájsť najbližší prvok podľa jeho vlastností. Výpočet prebieha pomocou vzorca Euklidovskej vzdialenosti. Táto metóda výpočtu bola posúdená v testovacom procese ako presnejšia oproti výpočtu pomocou Manhattanskej vzdialenosti. Pri voľbe metódy CNN prebieha klasifikačný proces na základe neurónových sietí. Výpočet je preddefinovaný v MATLAB funkcii classify.

Posledné okno *Rozpoznávanie snímkov* v aplikácii Matlab zahŕňa celý klasifikačný proces. Pod pojmom Hľadaná snímka rozumieme snímku, ktorú chceme klasifikovať. Je to snímka, ktorú máme umiestnenú v osobitnej zložke so snímkami, ktoré chceme rozpoznávať pomocou biometrického algoritmu. V okne rozpoznaná snímka sa nám zobrazí snímka z uloženej databázy, ktorá bola klasifikačným algoritmom posúdená ako zhodná s hľadanou snímkou.

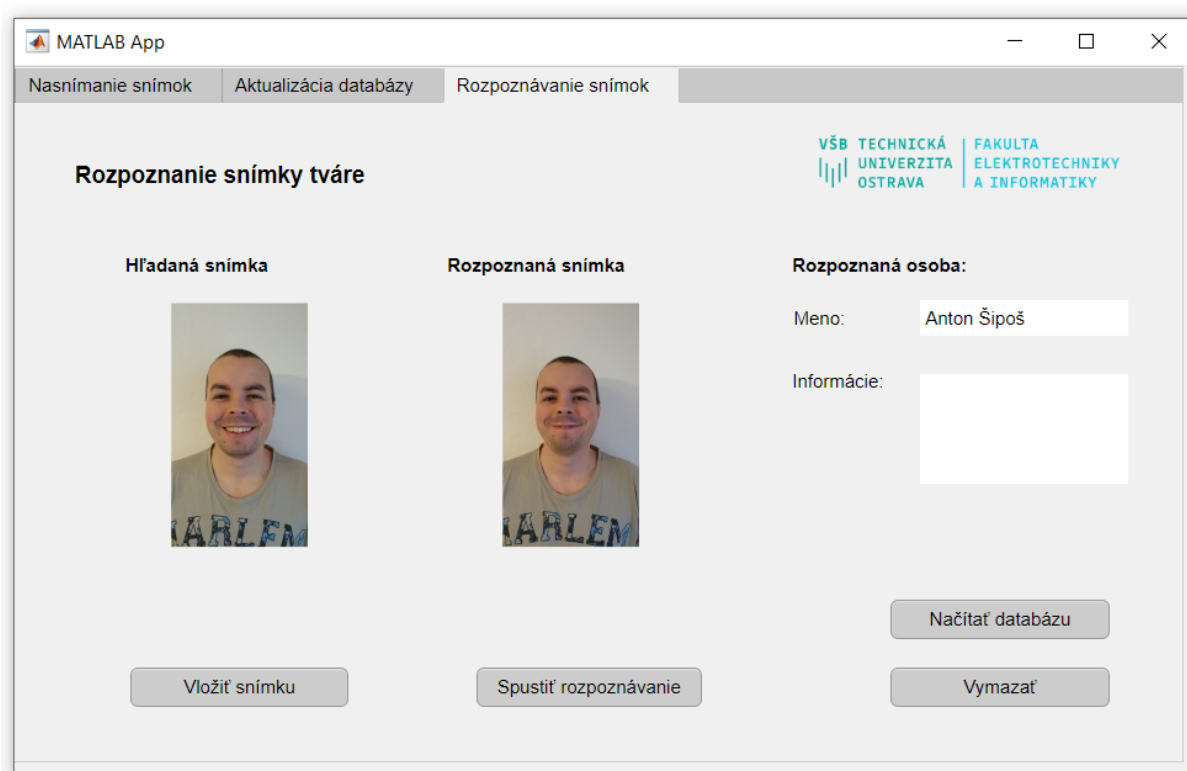
V sekcii Rozpoznaná osoba sú predpripravené okná meno rozpoznanej osoby a informácie. Funkčnosť týchto okien sme čiastočne otestovali v databáze snímkov Moja databáza. Pri použití na onkologickom oddelení je možnosť vylepšiť aplikáciu o zobrazenie údajov o rozpoznanom pacientovi z nemocničnej databázy, z vytvorenej databázy v Exceli či iným spôsobom, avšak sfunkčnenie spomínanej sekcie aplikácie presahuje zadanie a možnosti diplomovej práce. Na obrázku č.38 môžeme vidieť ukážku prostredia karty *Rozpoznávanie snímkov* pred začatím predikcie identity.



Obrázok 38: Karta „Rozpoznávanie snímkov“ pred započatím procesu predikcie identity

[zdroj: autorka]

Na obrázku č. 38 môžeme vidieť zobrazenie v aplikácii po ukončení rozpoznávacieho procesu. Na úvod používateľ pomocou tlačidla *Vložiť snímku* vyberie fotku tváre subjektu, ktorého chce rozpoznať pomocou biometrického systému identifikácie tváre. Po kliknutí sa zobrazí prehliadacie okno domovského počítača v ktorom si používateľ zvolí snímku hľadanej tváre. Po zvolení snímky sa v okne hľadaná snímka zobrazí vybraný obrázok. Na spustenie rozpoznávacieho procesu je potrebné kliknúť na tlačidlo *Spustiť rozpoznávanie*. O pár sekúnd sa v okne rozpoznaná snímka zobrazí fotka hľadanej osoby a v sekcii rozpoznaná osoba meno a prípadne aj informácie o rozpoznanej osobe. Tým, že sa zobrazí snímka z databázy a taktiež údaje rozpoznanej osoby, znížime možnosť chybného priradenia pri z prípadnej chybe systému. Používateľ tak bude mať možnosť aj empiricky overiť, že rozpoznanie dopadlo úspešne. Na opakované použitie systému slúži tlačidlo *Vymazať*, ktoré vymaže vložené aj rozpoznané údaje a používateľ tým získava možnosť rozpoznať snímku ďalšej osoby. Pokiaľ sa používateľ spustení aplikácie chce vyhnúť opätovnej aktualizácii databázy snímok, pretože žiadne nové snímky od posledného spustenia do databázy nevkladal použije tlačidlo *Načítať databázu*. Ihneď po kliknutí na toto tlačítko sa otvorí prehľadávacie okno, v ktorom si zvolí MATLAB súbor s uloženými konštantami z workspace predošlej aktualizácie.



Obrázok 39: Ukážka okna „Rozpoznanie snímok“ po spustení predikcie identity [zdroj: autorka]

Záver

Cieľom tejto diplomovej práce bolo vyvinúť spoľahlivý systém na biometrickú identifikáciu onkologických pacientov a tým uľahčiť identifikáciu a zabrániť omylom, ktoré by mohli spôsobiť podanie nesprávnej formy či dávky terapie. Prvá časť teórie sa zaoberá posúdením vplyvov chemoterapie a rádioterapie na pacienta s onkologickým ochorením. Z podrobne popísaných vedľajších účinkov majú pre nás význam hlavne tie, ktoré ovplyvňujú vonkajší vzhľad pacientovej tváre. Následne je popísaný princíp a vlastnosti biometrického systému a porovnanie možností získavania biometrických markantov na základe odtlačku prsta, snímania tváre a dúhovky.

Vzhľadom na nízke množstvo relevantných článkov v rešeršnej časti, zaoberajúcich sa problematikou využitia biometrických systémov v klinickom prostredí je možné usúdiť, že zavádzanie týchto systémov je ešte len na počiatku. Zosumarizovaný teoretický rozbor ako aj praktická časť tejto diplomovej práce má taktiež snahu zvýšiť dostupnosť informácií o problematike biometrickej identifikácie v zdravotníckom prostredí.

Po naštudovaní dostupnej literatúry a skonsolidovaní požiadaviek a možností oddelenia CyberKnife vo Fakultnej Nemocnici v Ostrave, bola zvolená metóda identifikácie na základe tváre. Do množstva výhod, ktorými identifikácia tváre disponuje (nízke obstarávacie náklady, nízke požiadavky na hardware a iné), patrí aj jej bezkontaktnosť, ktorá je významná najmä v tomto období, keď náš život ovplyvňuje vírusové ochorenie covid-19 a onkologickí pacienti spadajú do rizikovej kategórie.

Praktická časť pozostáva z podrobného opisu používaných databáz. Vysoká variabilita dát, ktorú zabezpečuje použitie fotografií z rôznych databáz, zaistili dôkladné otestovanie rôznych vplyvov na úspešnosť systému. Ako problémová sa ukázala byť kombinácia rozmazanej snímky a nehomogénneho pozadia a taktiež výrazné pootočenie tváre nad 45 stupňov. Súčasťou testovania bolo aj posúdenie vplyvu množstva trénovacích fotiek na úspešnosť rozpoznávania. Optimálny počet fotiek v trénovacej databáze bol určený na 5. Výsledky testov sú zahrnuté do požiadaviek na správne snímanie osoby a boli predstavené odborníkovi na oddelení Cyberknife.

Pri implementácii algoritmu v softwarovom prostredí MATLAB bola posudzovaná úspešnosť biometrického systému na troch extrakčných algoritmoch a taktiež klasifikačných algoritmoch založených na rozdielnych matematických výpočtoch. Z hľadiska úspešnosti sa ukázala byť ako najvhodnejšia analýza hlavných komponentov spolu s klasifikáciou na základe metódy najbližšieho suseda, ktorá je založená na výpočte pomocou Euklidovskej vzdialenosti. Z hľadiska trvania trénovacieho procesu bola posúdená ako najvhodnejšia metóda konvolučných neurónových sietí.

Finálnym „produktom“ diplomovej práce je používateľské rozhranie umožňujúce aktualizáciu databázy, čo predstavuje trénovací proces a samotné rozpoznávanie. Nadstavbou aplikácie, ktorá značne urýchlí fotografovanie pacienta je karta *Nasnímanie snímok*, ktorá je prepojená s webkamerou počítača. Výhodou je, že algoritmus fotografovania disponuje lokalizáciou tváre a teda pri akomkoľvek prekrytí časti tváre nedochádza k snímaniu. Snímky je možné použiť pri vkladaní novej tváre pacienta do databázy biometrického identifikačného systému alebo pri rozpoznávaní.

Možným pokračovaním diplomovej práce je prepojenie používateľského grafického rozhrania s databázou obsahujúcou kontaktné údaje, osobné informácie, prípadne popis priebehu liečby identifikovaných pacientov.

Použitá literatura

- [1] SURI, Jasjit S., David Lynn WILSON a Swamy LAXMINARAYAN, ed. Handbook of biomedical image analysis. Volume I, Segmentation Models. New York: Kluwer Academic/Plenum Publishers, c2005. Topics in biomedical engineering international book series. ISBN 0-306-48550-8. BAURA, Gail D. System theory and practical applications of biomedical signals. Piscataway: IEEE Press ; Hoboken, c2002. IEEE Press series on biomedical engineering. ISBN 0-471-23653-5
- [2] WOJNAR, Leszek. Image analysis: applications in materials engineering. Boca Raton: CRC Press, c1999. CRC series in materials science and technology. ISBN 0-8493-8226-2.
- [3] SEUL, Michael, Lawrence O'GORMAN a Michael J. SAMMON. Practical algorithms for image analysis: description, examples, and code. Cambridge: Cambridge University Press, 2000. ISBN 0-521-66065-3.
- [4] TIDY, Dr. Colin. *Radiotherapy* [online]. 23.12.2015, 2695 (v27) [cit. 2020-09-21]. Dostupné z: <https://patient.info/doctor/radiotherapy-pro>
- [5] ROSEN, Eliot M., Regina DAY a Vijay K. SINGH. New Approaches to Radiation Protection. *Frontiers in Oncology* [online]. 2015, 4 [cit. 2020-09-30]. ISSN 2234-943X. Dostupné z: [doi:10.3389/fonc.2014.00381](https://doi.org/10.3389/fonc.2014.00381)
- [6] SCHULMEISTER, Lisa. Patient Misidentification in Oncology Care. *Clinical Journal of Oncology Nursing* [online]. 2008, 12(3), 495-498 [cit. 2020-09-30]. ISSN 1092-1095. Dostupné z: [doi:10.1188/08.CJON.495-498](https://doi.org/10.1188/08.CJON.495-498)
- [7] KERR, David J. a Daniel G. HALLER. *Oxford Textbook of Oncology*. 3. United Kingdom: Oxford University Press, 2016. ISBN 9780191065101.
- [8] RULL, Gurvinder. Chemotherapy. In: <https://patient.info> [online]. The Information Standard, 14.11.2017 [cit. 2020-09-21]. Dostupné z: <https://patient.info/cancer/cancer/chemotherapy>
- [9] FEDOROVÁ, Katarína. Chemoterapia. In: hematologickypacient.sk [online]. Bratislava: Združenie pacientov s hematologickými malignitami [cit. 2020-09-30]. Dostupné z: <https://www.hematologickypacient.sk/sk/content/147-chemoterapia>
- [10] Side Effects of Radiation Therapy. In: www.cancer.net [online]. Alexandria, VA, USA: ASCO, 12.2018 [cit. 2020-09-21]. Dostupné z: <https://www.cancer.net/navigating-cancer-care/how-cancer-treated/radiation-therapy/side-effects-radiation-therapy>
- [11] Radiation Therapy Side Effects. In: www.cancer.gov [online]. MD, USA, 1.5.2018 [cit. 2020-09-21]. Dostupné z: <https://www.cancer.gov/about-cancer/treatment/types/radiation-therapy/side-effects>
- [12] MADDOCKS-JENNINGS, Wendy, Jenny M WILKINSON a David SHILLINGTON. Novel approaches to radiotherapy-induced skin reactions: A literature review. *Complementary Therapies in Clinical Practice* [online]. 2005, 11(4), 224-231 [cit. 2020-09-30]. ISSN 17443881. Dostupné z: [doi:10.1016/j.ctcp.2005.02.001](https://doi.org/10.1016/j.ctcp.2005.02.001)

- [13] VIŠŇOVCOVÁ, Nadežda, Ingrid TONHAJZEROVÁ, Viera JAKUŠOVÁ, Helena BARÁNI a Ján JAKUŠ. Rádioterapia a včasné postradiačné zmeny na koži: Radiotherapy and early radiation-induced skin changes. *Onkológia*. Bratislava: SOLEN, 2010, 5(5), 292-295. ISSN 1336-8176.
- [14] FEYER, Petra, Franziska JAHN a Karin JORDAN. Prophylactic Management of Radiation-Induced Nausea and Vomiting. *BioMed Research International* [online]. 2015, 2015, 1-8 [cit. 2020-09-30]. ISSN 2314-6133. Dostupné z: doi:10.1155/2015/893013
- [15] NATIONAL CANCER INSTITUTE. *Nerve Problems (Peripheral Neuropathy) and Cancer Treatment* [online]. In: . 15.1.2020 [cit. 2020-09-24]. Dostupné z: <https://www.cancer.gov/about-cancer/treatment/side-effects/nerve-problems>
- [16] MORGAN, S., R.A. ANDERSON, C. GOURLEY, W.H. WALLACE a N. SPEARS. How do chemotherapeutic agents damage the ovary? *Human Reproduction Update* [online]. 2012, 18(5), 525-535 [cit. 2020-09-30]. ISSN 1460-2369. Dostupné z: doi:10.1093/humupd/dms022
- [17] UNIVERZITA KOMENSKÉHO V BRATISLAVE, Prírodovedecká fakulta. *Bezpečnostné predpisy pre prácu v rádioizotopovom pracovisku* [online]. 7 [cit. 2020-09-21]. Dostupné z: https://fns.uniba.sk/uploads/media/Bezpecnostne_predpisy_pre_pracu_v_radioizotopovom_pracovisku_.pdf
- [18] Side effects: Chemotherapy. In: *NHS* [online]. England, UK, 29.1.2020 [cit. 2020-09-30]. Dostupné z: <https://www.nhs.uk/conditions/chemotherapy/side-effects/>
- [19] ANN, Pietrangelo. The Effects of Chemotherapy on Your Body. In: *Healthline* [online]. San Francisco, CA, USA, 2.12.2019 [cit. 2020-09-30]. Dostupné z: <https://www.healthline.com/health/cancer/effects-on-body>
- [20] VILÉM, JELEN. *Biometrická brána využívající kamer pro identifikaci osob*. Brno, 2019. Diplomová práce. VUT Brno. Vedoucí práce Tomáš Goldmann.
- [21] KELLNER, Jan. *Implementace fyziologické identifikace do bezpečnostního systému firmy*. Ostrava, 2016. Diplomová práce. VŠB-Ostrava. Vedoucí práce Ing. Pavel Staša, Ph.D.
- [22] ZATLOUKAL, Filip. *Analýza a porovnání biometrických metod*. Praha, 2012. Bakalářská práce. Vysoká škola ekonomická v Praze. Vedoucí práce Ing. Zuzana Šedivá, Ph.D.
- [23] WEILING, F. Neue Ergebnisse zur Statistischen Vorgeschichte der Mendelschen Versuche. *Biometrics* [online]. 1971, 27(3) [cit. 2020-10-05]. ISSN 0006341X. Dostupné z: doi:10.2307/2528608
- [24] CHAMPOD, Christophe a Massimo TISTARELLI. *Handbook of Biometrics for Forensic Science*. Imprint: Springer, 2017. Advances in Computer Vision and Pattern Recognition. ISBN 9783319506739.
- [25] KLÍMEK, Martin. *Biometrická identifikace a verifikace*. Zlín, 2012. Bakalářská práce. Univerzita Tomáše Bati ve Zlíne. Vedoucí práce JUDr. Vladislav Štefka.

- [26] SRIRAM, Madavath. *Iris Recongition*. Iris Recongition. Patancheru. Dostupné z: <http://www.scribd.com/doc/20051739/IrisRecongition>. TRR College of Engineering, 2009. TRR College of Engineering.
- [27] RAK, Roman, Vašek MATYÁŠ a Zdeněk ŘÍHA. *Biometrie a identita člověka ve forenzních a komerčních aplikacích*. Praha: Grada, 2008. Profesionál. ISBN 978-80-247-2365-5.
- [28] PROCHÁZKA, Matouš. *Vestavěný biometrický systém pro identifikaci osob ve zdravotnickém zařízení založený na principech otisku prstu*. Ostrava, 2018. Diplomová práce. VŠB-TUO. Vedoucí práce Ing. Zdeněk Macháček Ph.D.
- [29] DAMKLIANG, Kasikrit. *AT&T Database of Faces* [online]. s. 1 [cit. 2021-02-18]. Dostupné z: <https://www.kaggle.com/kasikrit/att-database-of-faces/activity>
- [30] SPACEK, Libor. *Facial Images: Faces94* [online]. In: Praha. 2009, s. 1 [cit. 2021-02-18]. Dostupné z: <https://cmp.felk.cvut.cz/~spacelib/faces/faces94.html>
- [31] LODERER, Marek a Jarmila JARMILA PAVLOVIČOVÁ. *BIOMETRIA: Rozpoznávanie ľudských tvárí* [online]. 1. 2016 [cit. 2021-02-18]. Dostupné z: http://ibooks.sk/publ/14loderer/pdf/14_biometria_monografia.pdf
- [32] LIETAVCOVÁ, Zuzana. *Konvoluční neuronové sítě* [online]. Brno, 2018 [cit. 2021-03-19]. Dostupné z: https://www.vutbr.cz/www_base/zav_prace_soubor_verejne.php?file_id=180844. Diplomová práce. VUT Brno. Vedoucí práce Doc. Ing. František Zbořil, CSc.

Zoznam príloh

Příloha A: Trénovacia časť algoritmu na základe analýzy hlavných komponentov	I
Příloha B: Testovacia časť algoritmu na základe analýzy hlavných komponentov	II
Příloha C: Trénovacia časť algoritmu na základe Lineárnej diskriminačnej analýzy	III
Příloha D: Testovacia časť algoritmu na základe Lineárnej diskriminačnej analýzy	V
Příloha E: Trénovacia časť algoritmu na základe konvolučnej neurónovej siete	VI
Příloha F: Testovacia časť algoritmu na základe konvolučnej neurónovej siete	VIII
Příloha G: Příloha v IS Edison	IX

Příloha A: *Trénovacia časť algoritmu na základe analýzy hlavných komponentov*

```
%% Algoritmus rozpoznávania tváre založený na PCA (Analýze hlavných komponentov)
% 1. TRÉNOVACIA ČASŤ
%-----
n=input('Počet snímkov v zložke na tréovanie: '); % počet snímkov na tréovanie (eigenspace)
L=50; % počet dominantných vlastných hodnôt
M=200; N=112; % veľkosť obrázka v pixeloch (M=výška; N=šírka)
X=zeros(n, (M*N)); % definovanie nulovej matice dátových súborov
T=zeros(n,L); % definovanie nulovej transformovanej matice
display ('Načítavanie fotiek ...');

for count=1:n
    I=imread(sprintf('%d.jpg',count)); % načítanie obrázkov v zložke tréovacia databáza
    I=rgb2gray(I); % prevod do odtieňov sivej
    I = imadjust(I,stretchlim(I),[]); % úprava kontrastu
    X(count,:)=reshape(I, [1,M*N]); % premena 2D obrázkov na 1D vektor
end
Xb=X; % uloženie matice na ďalšie použitie

m=mean(X); % výpočet priemeru z každého obrázka
for i=1:n
    X(i,:)=X(i,:)-m; % odpočítanie priemeru z každého 1D vektora
end

Q=(X'*X)/(n-1); % nájdenie kovariančnej matice
[Vecm,Evalm]=eig(Q); % získanie vlastných hodnôt a vlastných vektorov
Eval=diag(Evalm); % extrahovanie všetkých vlastných hodnôt
[Evalsorted,Index]=sort(Eval,'descend'); % triedenie vlastných hodnôt
Evecssorted=Vecm(:,Index); % redukovaná transformovaná matica
Ppca=Evecssorted(:,1:L); % výber dominantných eigenvalues

for i=1:n
    T(i,:)=(Xb(i,:)-m)*Ppca; % prepočítanie každého obrázku do PCA priestoru
end

save('pca_konstanty_mydat.mat','M','N','m','n','T','Ppca')
display ('Tréovanie je úspešne ukončené')
```

Příloha B: *Testovacia časť algoritmu na základe analýzy hlavných komponentov*

```
% Algoritmus založený na PCA (Analýze hlavných komponentov)
% 2. TESTOVACIA ČASŤ
%-----
load pca_konstanty_mydat;                                % načítanie premenných

[filename,pathname]=uigetfile('*.','Vyber snímku zo zložky: Testovacia databáza');
filewithpath=strcat(pathname,filename);
img=imread(filewithpath);                                % prečítanie snímky
imgo=img;                                                 % uloženie snímky na zobrazenie
img=rgb2gray(img);                                        % prevod do šedej škály
img=imadjust(img,stretchlim(img),[]);                     % úprava kontrastu
img=imresize(img,[M,N]);                                  % zmena veľkosti
img=double(reshape(img,[1,M*N]));                         % premena na 1D vektor

imgpca=(img-m)*Ppca;                                       % prevedenie obrázku do priestoru PCA (eigenspace)

%% KLASIFIKÁCIA = metóda najbližšieho suseda

Euc_dist = [];                                           % výpočet na základe Euklidovskej vzdialenosti
for i = 1 : n
    q = T(i,:);
    temp = (norm(imgpca-q))^2;
    Euc_dist = [Euc_dist temp];
end

[Euc_dist_min , indx] = min(Euc_dist);                   % určenie minimálnej vzdialenosti = nájdenie zhody
resultimg=imread(sprintf('%d.jpg', indx));               % načítanie zhodného snímku

%% Zobrazenie snímkov
subplot(121)
imshow(imgo); title('Hľadaná tvár');                     % zobrazenie snímky z testovacej databázy
subplot(122)
imshow(resultimg); title('Rozpoznaná tvár');               % zobrazenie snímky z trénovacej databázy
```

Příloha C: Trénovacia časť algoritmu na základe Fischerovej lineárnej diskriminačnej analýzy

```
%% Algoritmus rozpoznávania tváre založený na FLDA (Fisherface Linear Discriminant Analysis)
% TRENOVACIA ČASŤ
% -----
n=input('Počet snímkov v zložke na tréovanie: '); % počet snímkov na tréovanie (eigenspace)
M=112; N=92; % veľkosť obrázka v pixeloch zredukovaná na polovicu
display('Načítavanie fotiek ...');
X = []; % definovanie nulovej matice datových súborov
for count=1:n
    I=imread(sprintf('%d.jpg',count)); % načítanie všetkých obrázkov v zložke trénovacia_databáza
    I=rgb2gray(I); % prevod do odtieňov sivej
    I = imadjust(I,stretchlim(I),[]); % úprava kontrastu
    X(:,count)=reshape(I,[1,M*N]); % [MNxn] premena 2D obrázkov na 1D vektor
end
Xb=X; % uloženie databázy na ďalšie použitie
C_number = (size(X,2)/2); % počet tried
C_population = 2; % počet obrázkov v každej triede

m=[]; % definovanie matice na výpočet priemeru
m = mean(X,2); % [M*Nx1] výpočet priemeru z každého obrázka
A = X - repmat(m,1,n); % odpočítanie priemeru z každého 1D vektora
Q=(A'*A); % nájdenie kovariančnej matice
[Evecm,Evalm]=eig(Q); % získanie vlastných hodnôt a vlastných vektorov
L = []; % výber dominantných eigenvalues
for i = 1 : n-C_number
    L = [L Evecm(:,i)];
end

V_PCA=[]; % definovanie nulovej matice
V_PCA = A * L; % výpočet vlastných vektorov kovariančnej matice Q
ProjectedImages_PCA = []; % prepočítanie každého obrázku do PCA priestoru=eigenfaces
for i = 1 : n
    temp = V_PCA'*A(:,i);
    ProjectedImages_PCA = [ProjectedImages_PCA temp];
end
```

```

%% základ LINEÁRNEJ DISKRIMINAČNEJ ANALÝZY
m_PCA = mean(ProjectedImages_PCA,2); % celkový priemer v eigenspace
ma = zeros(n-C_number,C_number);
Sw = zeros(n-C_number,n-C_number); % vytvorenie matice vnútrotriedneho rozptylu (Within Scatter Matrix)
Sb = zeros(n-C_number,n-C_number); % vytvorenie matice medzitriedneho rozptylu (Between Scatter Matrix)

for i = 1 : C_number
    ma(:,i) = mean( ( ProjectedImages_PCA(:, ((i-1)*C_population+1):i*C_population) ), 2 )';

    S = zeros(n-C_number,n-C_number);
    for j = ( (i-1)*C_population+1 ) : ( i*C_population )
        S = S + (ProjectedImages_PCA(:,j)-ma(:,i))*(ProjectedImages_PCA(:,j)-ma(:,i))';
    end

    Sw = Sw + S; % matica vnútrotriedneho rozptylu
    Sb = Sb + (ma(:,i)-m_PCA) * (ma(:,i)-m_PCA)'; % matica medzitriedneho rozptylu
end

[J_eig_vec, J_eig_val] = eig(Sb,Sw); % výpočet Fisherovho diskriminačného základu
J_eig_vec = fliplr(J_eig_vec);

V_Fisher=[];
for i = 1 : C_number-1 % eliminácia nulových eigenvectors
    V_Fisher(:,i) = J_eig_vec(:,i); % výber dominantných vlastných vektorov
end

ProjectedImages_Fisher=[]; % prepočítanie obrázkov do Fisherovho lineárneho priestoru
for i = 1 : C_number*C_population
    ProjectedImages_Fisher(:,i) = V_Fisher' * ProjectedImages_PCA(:,i);
end

save('fld_konstanty_ATT.mat','M','N','n','m','V_Fisher','V_PCA','ProjectedImages_Fisher')
display ('Trénovanie je úspešne ukončené')

```


Příloha D: *Testovacia časť algoritmu na základe Fischerovej lineárnej diskriminačnej analýzy*

```
%% Algoritmus rozpoznávania tváre založený na FLDA ((Fisherface Linear Discriminant Analysis))
% 2. TESTOVACIA ČASŤ
%-----
load fld_konstanty_ATT; % načítanie premenných
[filename,pathname]=uigetfile('*.','Výber snímku zo zložky: Testovacia databáza');
filewithpath=strcat(pathname,filename);
img=imread(filewithpath); % prečítanie snímky
imgo=img; % uloženie snímky na ďalšie spracovanie
img=rgb2gray(img); % prevod do šedej škály
img = imadjust(img,stretchlim(img),[]); % úprava kontrastu
img=double(reshape(img,[M*N,1])); % premena na jednotkový vektor

Difference = img-m; % odčítanie priemeru
img_lda = V_Fisher' * V_PCA' * Difference; % prevedenie obrázku do priestoru LDA

%% KLASIFIKÁCIA = metóda najbližšieho suseda
% Manhattanská vzdialenosť

distarray=zeros(n,1); % definovanie nulovej matice
for i=1:n % výpočet vzdialenosti eigenfaces k zvolenej snímke
    distarray(i)=sum(abs(ProjectedImages_Fisher(:,i)-img_lda));
end

[result,indx]=min(distarray); % určenie minimálnej vzdialenosti = nájdenie zhody
resultimg=imread(sprintf('%d.jpg', indx));

%% Zobrazenie snímok
subplot(121)
imshow(imgo); title('Hľadaná tvár'); % zobrazenie snímky z testovacej databázy
subplot(122)
imshow(resultimg); title('Rozpoznaná tvár'); % zobrazenie snímky z trénovacej databázy
```

Příloha E: *Trénovacia časť algoritmu na základe konvolučnej neurónovej siete*

```
%% Algoritmus rozpoznávania tváre založený na CNN (Konvolučná neurónová sieť)
% 1. TRÉNOVACIA ČASŤ
%-----
Dataset = imageDatastore('Trenovacia_databaza_mydat','IncludeSubfolders',...
    true,'LabelSource','foldernames'); % načítanie fotiek z trénovacej databázy
[Train_Dataset,Validation_Dataset] = splitEachLabel(Dataset,3.0);

net=googlenet; % použitie predučenej siete GoogleNet
Input_Layer_size= net.Layers(1).InputSize;

Layer_Graph = layerGraph(net); % ukážka vrstiev
Feature_Learner = net.Layers(142); % premenovanie vrstvy č.142
Output_Classifier= net.Layers(144); % premenovanie vrstvy č.144

Classes=numel(categories(Train_Dataset.Labels)); % počet kategórií (tried)

New_Feature_Learner = fullyConnectedLayer(Classes,... % definovanie novej vrstvy 142
    'Name','Facial Feature Learner',...
    'WeightLearnRateFactor', 10,...
    'BiasLearnRateFactor', 10);

New_Classifier_Layer = classificationLayer('Name','Face Classifier'); % definovanie novej vrstvy 144
    % nahradenie vrstiev
Layer_Graph = replaceLayer(Layer_Graph, Feature_Learner.Name, New_Feature_Learner);
Layer_Graph = replaceLayer(Layer_Graph, Output_Classifier.Name, New_Classifier_Layer);
analyzeNetwork(Layer_Graph); % zobrazenie novej architektúry siete

Pixel_Range = [-35 35]; % definícia rozsahu pixelov
Scale_Range = [0.95 1.2]; % definícia rozsahu stupnice

Image_Augmenter = imageDataAugmenter(... % augmentácia - náhodné zmeny obrázkov
    'RandXReflection',true,... % horizontálny odraz
    'RandXTranslation', Pixel_Range,... % horizontálne posunutie pixelov
    'RandYTranslation',Pixel_Range, ... % vertikálny posuv pixelov
```

```

    'RandXScale', Scale_Range,...           % rozťahnutie alebo zmenšenie (horizontálne)
    'RandYScale',Scale_Range);              % rozťahnutie alebo zmenšenie (vertikálne)

% zmena rozšírenia vstupnej vrstvy trénovacia databáza
Augmenting_Training_Image= augmentedImageDatastore(Input_Layer_size(1:2),...
    Train_Dataset, ...
    'DataAugmentation',Image_Augmenter);
% zmena rozšírenia vstupnej vrstvy testovacia databáza
Augmenting_Testing_Image = augmentedImageDatastore(Input_Layer_size(1:2),Validation_Dataset);

%% Definovanie podmienok
Size_of_Mimibatch = 5;                     % počet prvkov
Validation_Frequency = floor(numel(Augmenting_Training_Image.Files)/Size_of_Mimibatch); % frekvencia overovania
% stochastický gradient s hybnosťou(aktualizácia váh)

Training_options = trainingOptions('sgdm', ... % počet prvkov
    'MiniBatchSize', Size_of_Mimibatch, ... % frekvencia overovania
    'InitialLearnRate', 3e-4, ... % stochastický gradient s hybnosťou(aktualizácia váh)
    'MaxEpochs', 5, ... % počiatková rýchlosť učenia
    'Shuffle', 'every-epoch',... % počet epóch
    'ValidationData', Augmenting_Testing_Image,... % kontrola nad premiešaním dát
    'ValidationFrequency', Validation_Frequency,... % frekvencia overovania trénovanej siete
    'Verbose', false,... % zobrazuje informácie o priebehu tréningu
    'Plots', 'training-progress'); % vykreslenie priebehu tréningu

% trénovanie neurónovej siete
net = trainNetwork(Augmenting_Training_Image, Layer_Graph, Training_options);

save('cnn_konstanty_mydat.mat','net')
display ('Trénovanie je úspešne ukončené')

```

Příloha F: *Testovacia časť algoritmu na základe konvolučnej neurónovej siete*

```
%% Algoritmus rozpoznávania tváre založený na CNN
% TESTOVACIA ČASŤ
%-----
clc; close all; clear all;

load cnn_konstanty_mydat;                                % načítanie premenných
[filename,pathname]=uigetfile('*.','...
    'Vyber snímku zo zložky: Testovacia databáza');
filewithpath=strcat(pathname,filename);
img=imread(filewithpath);                                % prečítanie snímky
I=imresize(img,[224 224]);                                % zmena rozmeru

[label, probability]= classify(net,I);                     % klasifikácia

figure                                                    % zobrazenie rozpoznanej snímky a názvu
imshow(img);
title({char(label),num2str(max(probability),2)});
```

Obsah:

- Diplomová práce vo formáte PDF/A
- Zdrojové kódy
- Aplikácia s používateľským rozhraním
- Vzor databázy snímkov (fotky z vytvorenej databázy)